



UNIVERSIDADE FEDERAL DO PARANÁ
SETOR DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA - PPGEE

MÁRCIO LEMOS DE OLIVEIRA

CONTROLE DE PH EM TORRE DE HCN STRIPPER
USANDO REDES NEURAIS

Mestrando: Márcio Lemos de Oliveira

Orientador: Professor titular José Manoel Fernandes Ph.D

CURITIBA

2011

MÁRCIO LEMOS DE OLIVEIRA

**CONTROLE DE PH EM TORRE DE HCN STRIPPER
USANDO REDES NEURAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração Sistemas Eletrônicos, Departamento de Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná, como parte das exigências para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Professor titular José Manoel Fernandes Ph.D

**CURITIBA
2011**



UNIVERSIDADE FEDERAL DO PARANÁ
Programa de Pós-Graduação em Engenharia Elétrica
PPGEE
Setor de Tecnologia

ATA DE DEFESA DE MESTRADO

Aos vinte e cinco dias do mês de agosto de 2011, na Sala PK 07 do Departamento de Engenharia Elétrica, foi instalada pelo Prof. Dr. Evelio Martín García Fernández, Coordenador do Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração em **Sistemas Eletrônicos**, a Banca Examinadora para a nonagésima oitava Dissertação de Mestrado do PPGEE. Estiveram presentes no ato, além do Coordenador do Curso de Pós-Graduação, professores, alunos e visitantes.

A Banca Examinadora, atendendo determinação do Colegiado do Programa de Pós-Graduação em Engenharia Elétrica, ficou constituída pelos professores doutores **José Manoel Fernandes (Orientador - UFPR)**; **Gideon Villar Leandro (UFPR)**, **Gustavo Henrique da Costa Oliveira (UFPR)** e **Cairo Lúcio Nascimento Junior (Instituto Tecnológico da Aeronáutica - ITA)**.


Às 10:00 horas, a banca iniciou os trabalhos, convidando o candidato **MARCIO LEMOS DE OLIVEIRA** a fazer a apresentação da dissertação intitulada **"CONTROLE DE PH EM TORRE DE HCN STRIPPER"**. Encerrada a apresentação, iniciou-se a fase de arguição pelos membros participantes.

Tendo em vista a dissertação e a arguição, a banca decidiu pela:


☒ **APROVAÇÃO**

☐ **NÃO APROVAÇÃO** do candidato, (de acordo com a determinação da Resolução 63/03-CEPE).


Curitiba, 25 de agosto de 2011.


Prof. Dr. José Manoel Fernandes


Prof. Dr. Gideon Villar Leandro


Prof. Dr. Gustavo Henrique da Costa
Oliveira


Prof. Dr. Cairo Lúcio Nascimento
Junior



TERMO DE APROVAÇÃO

MARCIO LEMOS DE OLIVEIRA

CONTROLE DE PH EM TORRE DE HCN STRIPPER USANDO REDES NEURAIS

Dissertação aprovada como requisito parcial para a obtenção do grau de Mestre no Curso de Pós-Graduação em Engenharia Elétrica, Setor de Tecnologia da Universidade Federal do Paraná, pela seguinte banca examinadora.

Orientador: Prof. José Manoel Fernandes Ph.D
Departamento de Engenharia Elétrica, UFPR

Prof. Cairo L. Nascimento Jr. Ph.D
Departamento de Engenharia Elétrica, ITA

Prof. Gustavo H. C. Oliveira. Dr
Departamento de Engenharia Elétrica, UFPR

Prof. Gideon Villar Leandro. Dr
Departamento de Engenharia Elétrica, UFPR

Curitiba, 25 de Agosto de 2011.

DEDICATÓRIA

Dedico este trabalho a minha querida mãe
e a minha irmã Simoni, que estiveram
sempre ao meu lado me apoiando e me
incentivando durante os momentos de
dificuldade.

AGRADECIMENTOS

Agradeço a Deus acima de tudo, pois foi através de sua benção e ensinamentos que pude superar os momentos de dificuldade durante a elaboração deste trabalho.

Ao amigo e orientador Prof. José Manoel Fernandes PhD pelo apoio, conselhos, paciência e orientações, mas principalmente pela oportunidade de me tornar uma pessoa melhor.

Ao Prof. Cairo L Nascimento PhD pelas sugestões e contribuições feitas em relação a este trabalho durante defesa.

Ao Prof. Dr. Gideon Villar Leandro pela complementação dada a esta dissertação durante a qualificação e a defesa.

Ao amigo Eng. Edemilson Bazoti pela compreensão e apoio durante o desenvolvimento deste trabalho.

À minha mãe e irmã, pela paciência, incentivo e compreensão nos momentos de dificuldade.

A todos os meus amigos de trabalho da Ultrafétil, que colaboraram, sendo com seu apoio ou compartilhando seu conhecimento adquirido com o tempo.

E a todos os outros que não foram mencionados aqui, mas que de alguma forma contribuíram e fizeram parte desta jornada.

Epígrafe

A percepção do desconhecido é a mais fascinante das experiências. O homem que não tem os olhos abertos para o misterioso passará pela vida sem ver nada.

(Albert Einstein)

SUMARIO

RESUMO	IX
ABSTRACT	X
LISTA DE FIGURAS	XI
1 INTRODUÇÃO	8
1.1 TEMA DO ESTUDO.....	8
1.2 OBJETIVOS.....	9
1.2.1 Objetivo Geral.....	9
1.2.2 Objetivo Especifico.....	9
1.3 ESTADO DA ARTE.....	10
1.4 ESTRUTURA DA DISSERTAÇÃO.....	14
2 METODOLOGIA	15
2.1 ESTUDO DA UNIDADE.....	15
2.2 COLETA DE DADOS.....	15
2.3 TRANSFERÊNCIA DOS CONTROLES DO SISTEMA ANALÓGICO PARA O SISTEMA DIGITAL	17
2.4 CONFIGURAÇÃO DOS CONTROLES.....	17
2.5 DADOS DE TESTE	18
2.6 TOOLBOX MATLAB	18
2.7 SIMULAÇÕES.....	20
3 CARACTERÍSTICAS DO CONTROLE DE PH	22
3.1 CONCEITO DE PH.....	22
3.2 CURVAS DE TITULAÇÃO	22
3.3 CONTROLE DE PH.....	29
4 REDES NEURAIS.....	32
4.1 MODELO DE NEURÔNIO	33
4.2 NEURÔNIO SIMPLES.....	34
4.3 FUNÇÕES DE ATIVAÇÃO.....	35
4.4 NEURÔNIO COM VETOR DE ENTRADA	37
4.5 ARQUITETURA DE REDES	38
4.5.1 Rede neural com uma camada de neurônios	39
4.5.2 Rede neural multicamadas	40
4.5.3 Redes neurais recorrentes.....	41
4.6 TIPOS DE CONEXÕES ENTRE OS NEURÔNIOS.....	42
5 REDES APLICADAS A CONTROLE	44
5.1 REDES NEURAIS DINÂMICAS	44
5.2 APLICAÇÃO REDES NEURAIS DINÂMICAS	45
5.3 CONTROLE ADAPTATIVO DE MODELO DE REFERENCIA.....	45
6 DESCRIÇÃO DO PROCESSO.....	50
6.1 UNIDADE DE GASEIFICAÇÃO	50
6.2 RECUPERAÇÃO DE CALOR.....	51
6.3 UNIDADE DE RECUPERAÇÃO DE CARBONO	52

7	RESULTADOS E DISCUSSÕES	58
7.1	IDENTIFICAÇÃO DO PROCESSO	58
7.2	CONTROLADOR NEURAL ADAPTATIVO DE MODELO DE REFERÊNCIA.....	62
7.3	TESTE DO MODELO DE CONTROLE NEURAL.....	67
8	CONCLUSÕES	70
9	REFERENCIAS	72

RESUMO

O controle de pH é comum em processos químicos, petroquímicos e indústrias de biotecnologia. Por exemplo, o pH da água residual de processo que é enviada para a estação de tratamento de efluentes, deve ser mantido dentro de limites ambientais rigorosas.

No entanto, o processo de neutralização do pH apresenta comportamento altamente não linear, devido a relação logarítmica entre a concentração de íons de hidrogênio $[H^+]$ e o nível do pH. Por esta razão, controladores convencionais como PID (Proporcional – Integral – Derivativo) ou técnicas de controle avançado baseado em teoria de sistemas lineares não apresentam resultado satisfatório quando aplicadas ao controle de pH.

Os controladores lineares são ajustados com base no maior ganho no ponto de neutralização, pH 7, a fim de manter o controle estável. Contudo devido ao comportamento não linear do pH nas regiões longe do ponto de neutralização os controladores não apresentam o comportamento desejado, levando ao consumo excessivo de reagentes devido a grandes oscilações no processo ou a resposta lenta da variável, nestas condições em muitos casos não é possível manter a malha de controle em automático.

Técnicas de controle, como método de modelagem online são desenvolvidas para processos não lineares e variantes no tempo. Essas técnicas são baseadas na aplicação de estruturas não lineares variantes no tempo, tais como modelo ARX, ou ainda modelo NARX que são aplicadas no controle de pH. Redes neurais artificiais são aplicadas em arquiteturas de controle, permitindo o modelamento e o controle de processos dinâmicos não lineares.

Este trabalho, tem por objetivo propor uma arquitetura de controle com base em redes neurais que controle o pH da água que sai da torre esgotadora de HCN.

Palavras-Chaves: Redes Neurais, Controle Adaptativo de Modelo de Referência, Controle de pH.

ABSTRACT

pH control is common in chemical, petrochemical, and biotechnology industries. For example, the pH of the wastewater process which is sent for effluent treatment plant, must be kept within strict environmental limits.

However, process of pH neutralization presents highly nonlinear behavior. This occurs due to the logarithmic relationship between the concentration of the hydrogen ions $[H^+]$ and the pH level. For this reason, conventional controllers such as PID controller (Proportional – Integral - Derivative) or control advanced techniques based in theory of linear systems don't present satisfactory results for pH control.

Linear controllers are adjusted based on the largest point gain in neutralization, pH 7, in order to keep the control stable. Nevertheless, the controller doesn't show the desired behavior in regions far from the point of neutralization, in many cases leading to excessive consumption of reagents due to fluctuations in the process or slow response of the process variable.

Some control techniques, such as a method of modeling processes are developed for online nonlinear time-varying. These techniques are based on the application of nonlinear structures in time variants, such as ARX model, or NARX model that are applied to control pH. Artificial neural networks are applied to control architectures, allowing the modeling and control of nonlinear dynamical processes.

This work aims to propose a control architecture based on neural networks that control the pH of the water that runs off of HCN exhausting.

Keywords: Neural Network, Model Reference Adaptive Control, pH Control.

LISTA DE FIGURAS

Figura 2.1 - Cartas gráficas unidades de registro.....	16
Figura 2.2 - Gráfico sistema digital de controle.....	16
Figura 2.3 - Tanque de neutralização	18
Figura 2.4 - Dados de processo tanque de neutralização	19
Figura 2.5 - Rede neural NARX para identificação.....	19
Figura 2.6 - Resposta de um elemento de saída para uma série temporal	20
Figura 2.7 - Dados de processo para simulação	21
Figura 3.1 - Curva de titulação de três ácidos comuns com soda	25
Figura 3.2 - O ganho da curva de titulação é o desvio do pH e causado por uma mudança na vazão reagente Δm	30
Figura 3.3 - Malha de pH com controlador linear.....	31
Figura 3.4 - Malha de pH com controlador não linear	31
Figura 4.1 - Modelo de Rede Neural.....	32
Figura 4.2 - Neurônio de McCulloch e Pitts.....	33
Figura 4.3 - Neurônio Simples	34
Figura 4.4 - Funções de ativação	36
Figura 4.5 - Função de ativação linear.....	36
Figura 4.6 - Função de ativação sigmoidal.....	37
Figura 4.7 - Neurônio com Vetor de Entrada	38
Figura 4.8 - Rede neural rede com uma camada de neurônios.....	39
Figura 4.9 - Rede neural multicamadas.....	41
Figura 4.10 - Rede neural recorrente.....	42
Figura 4.11 - Rede feedforward ou acíclica.....	42
Figura 4.12 - Rede feedback ou cíclica	43
Figura 5.1 - Rede neural dinâmica simples	44
Figura 5.2 - Controle adaptativo de modelo de referência.....	49

Figura 6.1 - Digrama em bloco gaseificação.....	50
Figura 6.2 - Fluxograma unidade de recuperação de carbono	53
Figura 7.1 - Arquitetura de controle proposta para torre de HCN	58
Figura 7.2 - Rede neural NARX.....	59
Figura 7.3 - Função tangente sigmoideal	59
Figura 7.4 - Função linear	59
Figura 7.5 - Dados para identificação do processo	60
Figura 7.6 - Sinal de saída AIC-12001.....	60
Figura 7.7 - Gráficos de correlação rede neural NARX.....	61
Figura 7.8 - Erro rede neural NARX.....	62
Figura 7.9 - Controlador MRAC	62
Figura 7.10 - Dados de processo para treinamento do controlador neural MRAC	63
Figura 7.11 - Controle de razão torre de HCN	64
Figura 7.12 - Dados do controle de Razão.....	64
Figura 7.13 - Correlação entre a saída da rede e o Alvo	65
Figura 7.14 - Saída real e saída estimada.....	66
Figura 7.15 - Diferença entre saída real e saída do controlador neural	66
Figura 7.16 - Resposta-1 do controlador neural	67
Figura 7.17 - Resposta-2 do controlador neural	68
Figura 7.18 - Resposta-3 do controlador neural	68
Figura 7.19 - Resposta-4 do controlador neural	69

LISTAS DE SIGLAS

AI-12001	Indicador de Analise
ARX	Auto Regressive Model with External Input
CO ₂	Dióxido de Carbono
CaCO ₃	Carbonato de Cálcio
DMC	Dynamic Matrix Control
DNNC	Dynamic Neural Network Control
EFRA	Exponential Resetting and Forgetting Algorithm
FFRC-12002	Controlador de Razão de Vazão
FIC-12001	Controlador Indicador de Vazão
HCL	Ácido Clorídrico
H ₂ S	Sulfeto de Hidrogênio
HCN	Ácido Cianídrico
IMC	Internal Model Control
MARC	Model Adaptive Reference Control
MCP	Modelo de McCulloch e Pitts
MORF	Modified Orthogonal Forward Regression
NARX	Average Model with External Input
NH ₃	Amônia
NNSI	Neural Network Stability Index
PI	Proporcional + Integral
PID	Proporcional + Integral + Derivativa
P&I	Process and Instrumentation
pH	Potencial Hidrogeniônico
RASF	Resíduo Asfáltico
RBF	Radial Basis Function
SDC	Sistema Digital de Controle

1 INTRODUÇÃO

1.1 Tema do Estudo

O processo de produção de amônia ocorre por meio da injeção de nitrogênio e hidrogênio em fornos catalisadores. O hidrogênio puro ou gás de síntese, utilizado na produção de amônia, é produzido em reatores a partir da queima do resíduo asfáltico (RASf), oxigênio e vapor.

O efluente dos reatores (gases e partícula de carbono) passa pela lavadora de carbono, onde as partículas de carbono formadas no estágio de reação são retiradas do gás cru com água, formando lama de carbono. A água residual é então enviada à unidade de recuperação de carbono, na qual o carbono é separado da lama de carbono. A água limpa é re-circulada para o processo, como água de retorno. A água que não pode ser reaproveitada passa através de filtros de areia, para remover partículas de carbono, e alimenta a torre de esgotamento de HCN (cianeto de hidrogênio). Além da água da unidade de recuperação de carbono a torre de HCN recebe água de outras unidades do processo. (Ultrafertil, 1978).

A função da torre esgotadora de HCN é remover HCN (cianeto de hidrogênio), H_2S (sulfeto de hidrogênio), CO_2 (dióxido de carbono) e NH_3 (amônia) presentes na água. Após a remoção dessas impurezas, a água é enviada para a estação de tratamento de efluentes.

Parte da água proveniente do processo contém HCN, H_2S e CO_2 e apresenta pH ácido. Nestas condições o processo de remoção ocorre em altas temperaturas, logo a temperatura de operação da torre e de aproximadamente 120°C . A outra parte da água proveniente do processo contém amônia, no entanto como o pH no interior da torre é ácido não é possível remover a amônia da água, pois o processo de remoção da amônia em água com pH ácido ocorre a baixas temperaturas. A solução encontrada para resolver este problema é manter o pH da água no interior da torre entre 10,5 e 11, ou seja, pH básico. Este processo de neutralização se dá

por meio da injeção de soda no interior da torre, mantendo o pH básico, sendo assim possível remover todos os contaminantes presentes na água sem a necessidade de alterar a temperatura de operação da torre de HCN.

Como o processo de neutralização do pH é altamente não linear, para o desenvolvimento do sistema de controle foram utilizadas redes neurais artificiais, que são empregadas no modelamento e controle de processos dinâmicos não lineares variantes no tempo. Este trabalho servirá como base para o desenvolvimento de uma arquitetura de controle neural em um sistema digital de controle (SDC), pois atualmente o sistema de controle da torre de HCN permite ao operador monitorar as condições de operação e fazer as correções necessárias manualmente.

1.2 Objetivos

1.2.1 Objetivo Geral

O objetivo geral deste trabalho é propor uma arquitetura de controle para controlar a injeção de soda na torre de HCN, a fim de manter o valor do pH da água de saída da torre entre 10,5 e 11,5, ou seja, pH básico.

1.2.2 Objetivo Especifico

A fim de alcançar o objetivo geral são estabelecidos os seguintes objetivos específicos:

- Pesquisar em artigos científicos, quais técnicas de controle com base em redes neurais são aplicadas a processo não lineares variantes no tempo.
- Propor arquitetura de controle de controle neural para controlar o pH.

- Estudar os manuais de operação e fluxogramas de processo da unidade de recuperação de carbono e demais unidades envolvidas para entender a arquitetura de controle da torre de HCN.
- Avaliar quais variáveis de processo devem compor a arquitetura de controle.
- Coletar dados de processo.
- Validar, em ambiente de simulação com dados de processo, a arquitetura de controle neural proposta.

1.3 Estado da Arte

Diversos são os estudos relacionados a sistemas de controle não lineares variantes no tempo. A seguir são apresentados alguns trabalhos sobre o assunto.

Hall e Seborg (1989) a fim de avaliar estratégias de controle avançadas, tais como controle adaptativo e controle multivariável, propuseram um experimento que consiste de dois tanques de neutralização de pH interconectados, ambos com fluxos de entrada ácido e base e o pH do efluente como fluxo de saída. Sendo as vazões de ácido e base as variáveis manipuladas e os níveis dos tanques as variáveis controladas. Os resultados mostraram que a estratégia de controle PID multivariável apresenta-se satisfatória para controle de pH, porém os controles de nível são sacrificados. No entanto, o controle adaptativo demonstrou bons resultados para o processo de neutralização do pH mesmo para variações nas vazões.

Gomm, Doherty e Williams (1996) propõe usar uma RBF (*Radial Basis Function*), rede neural artificial a fim de modelar a dinâmica do processo. Como o processo de neutralização do pH apresenta não linearidade significativa, variando no tempo e com variações no tempo morto, uma rede neural pode ser treinada para representar entradas e saídas dinâmicas do processo não linear usando dados

coletados. O modelo neural pode então ser usado para realizar um controle preditivo neural do processo.

Draeger, Engell, 2 Ranke (1995) apresentam um controle preditivo usando redes neurais para controlar o processo de neutralização do pH em escala de laboratório. Para isto, foi usado uma rede neural *feedforward* como modelo de predição não linear a fim de melhorar o algoritmo DMC (*Dynamic Matrix Control*) aplicado no controle de pH. Os dados para treinar a rede neural foram obtidos a partir da medição das entradas e saídas de um controlador PI de uma planta real. Os resultados experimentais apresentados mostram que a performance do algoritmo de controle é superior que o controlador convencional PI (Proporcional – Integral).

Elarafi e Hisham (2008) Ilustram o modelamento de planta de neutralização do pH usando técnicas empíricas a fim de comparar o controle preditivo usando rede neural artificial com controlador convencional PID. O modelo do processo é obtido através da verificação e identificação dos modelos empíricos a partir de dados experimentais do processo. Observa-se que o controle preditivo com base na rede neural apresenta desempenho superior ao controle PID convencional, com tempo de acomodação mais rápido, menor desvio da variável controlada e comportamento mais suave da variável manipulada.

Controladores adaptativos não lineares são projetados pela combinação de controladores não lineares com algoritmos de estimação de parâmetros. Kang, Yoon, Yang, e Yoon (2000) propõem o controle baseado *backstepping* que é combinado com estimadores de estado e parâmetros para trabalhar com variáveis de estado não mensuráveis e parâmetros desconhecidos resultando em um controlador adaptativo não-linear. As simulações mostraram desempenho constante em malha fechada, apesar da não linearidade, dos parâmetros inseridos e da indisponibilidade das variáveis de estado.

Liu, Li, e Wu (2009) ilustram um método de solução de redes neurais objetivando sistema de controle não linear com característica de atraso no tempo. O trabalho propõe uma rede neural associado à memória a qual é usado para modelo

um sistema de controle e um controlador Neuro-Fuzzy com estrutura de identificação inversa é adotado para controlar o processo não linear. Este método de controle Neuro-Fuzzy adota a estrutura de três camadas combinando rede neural e identificação inversa. O controle Neuro-Fuzzy proposto apresentou boa capacidade de identificação.

O trabalho apresentado por Nikraves e Stanford (1995) analisa a estabilidade do controle dinâmico de redes neurais (DNNC). O resultado obtido a partir da análise da DNNC é usado para definir o índice de estabilidade de rede neural (NNSI). Com o NNSI é determinado uma estrutura ideal de rede neural e o controlador DNNC para um processo com característica não linear.

Ge, Hang, e Zhang (1999) desenvolveram dois controladores com base em redes neurais adaptativas - por realimentação de estado (*state feedback*) e realimentação de saída (*output feedback*) - para sistemas não-lineares. Comparando com controladores adaptativos convencionais, os controladores propostos são aplicáveis a uma grande classe de sistemas não-lineares e não requer um período de treinamento *off-line* para a rede neural. As análises teóricas e os resultados das simulações mostram que os controladores propostos são eficazes no controle de sistemas dinâmicos não-lineares.

No trabalho apresentado por Bonilla, Baruch, Flores, Goire, e Nenkov (2003) é aplicado uma arquitetura de um controle adaptativo de modelo de referência com base em redes neurais, o qual é composto por duas redes neurais, chamados; neuro identificador e neuro controlador. A estrutura de controle foi proposta para sistemas de estrutura variável, descrito pela percepção implícita, usando realimentação de saída. Os resultados obtidos neste trabalho mostraram que o controlador neural proposto apresentou resposta satisfatória.

Douratsos e Gomm, (2007) propõem o projeto de um controle adaptativo de modelo de referência com base em redes neurais para processos com elevado tempo de atraso. A arquitetura de controle proposta é aplicado a um processo químico altamente não-linear, controle de pH, que é usado para demonstrar a

aplicabilidade da técnica de controle proposta. Neste trabalho são apresentados os resultados do desempenho do controlador adaptativo de modelo de referencia com base em redes neural e comparado com os de um controlador adaptativo linear. Os resultados apresentados indicam que o controlador adaptativo com base em redes neurais apresentou resposta satisfatória no controle de pH.

No artigo, *Identification and Control of Dynamical Systems Using Neural Network*, Kumpati & Kannan (1990) são sugeridos modelos para identificação e controle de sistemas dinâmicos não lineares. Estes modelos incluem redes neurais multicamadas, bem como dinâmicas lineares, podem ser vista como generalização de redes neurais. Neste trabalho, para os modelos específicos dados, os valores de atraso de sinais relevantes no sistema são usados como entradas para a rede neural multicamadas. Os resultados das simulações para sistemas dinâmicos não-linear de baixa ordem revelam que a identificação e controle utilizando os métodos sugeridos podem ser muito eficazes.

No trabalho proposto por Hong, Morris, Karim, Zhang, e Luo (1996) uma arquitetura de controle preditivo não linear baseado no modelo NARX (Nonlinear Autoregressive with Exogenous Inputs) é aplicado no processo de neutralização de águas residuais. Nesta arquitetura de controle a estrutura inicial e os parâmetros são identificados off-line com o algoritmo MORF (Modified Orthogonal Forward Regression). A fim de evitar saturação do estimador devido a pouco estímulo dos dados, são utilizados mínimos quadrados modificados para compor o algoritmo EFRA (Exponential Resetting and Fogetting Algorithm) além de mudanças no setpoint são aplicadas para ajuste adaptativo dos parâmetros do molde NARX. Os resultados sugerem que o sistema de controle proposto obtem performance satisfatória no processo de neutralização do pH.

Arquiteturas de controle usando redes neurais artificiais são aplicadas com sucesso na elaboração de sistemas de controles para processos não lineares variantes no tempo. Contudo a maioria dos sistemas de controle são aplicados a tanques de neutralização de pH ou processo não lineares similares, não havendo nenhuma aplicação para processos com torre de esgotamento de HCN.

1.4 Estrutura da Dissertação

Esta dissertação está estruturada em oito capítulos, o Capítulo 1 apresenta a introdução, objetivo geral, objetivo específico, estado da arte e estrutura da dissertação. O Capítulo 2 descreve a metodologia aplicada no desenvolvimento do trabalho. O processo a ser controlado é descrito no Capítulo 3. No Capítulo 4 são descritas as redes neurais. No capítulo 5 é detalhada a aplicação das redes neurais no controle de processo. O capítulo 6 descreve o processo a ser controlado. Os resultados obtidos são descritos no capítulo 7. Finalmente, no capítulo 8 é apresentada as conclusões do trabalho.

2 METODOLOGIA

2.1 Estudo da Unidade

O estudo da unidade de recuperação de carbono compreendeu a leitura de manuais e procedimentos de operação, estudo de P&I e fluxogramas de processo, além do levantamento das malhas de controle envolvidas no controle da torre, sendo assim possível entender suas arquiteturas e funcionalidades. Também foi necessário observar o comportamento da unidade durante variações no processo, a fim de entender o funcionamento da unidade.

2.2 Coleta de dados

Para elaborar uma arquitetura de controle capaz de controlar o pH da torre esgotadora de HCN foi necessário coletar os dados das variáveis de entrada e saída da torre, a fim de observar e entender o comportamento do processo. Outro aspecto importante é que a partir dos dados de processo torna-se possível realizar simulações, que possibilitem avaliar quais as possíveis técnicas de controle que poderiam ser utilizadas.

No entanto, as malhas de controle que compõem a arquitetura de controle da torre de HCN eram controladas por controladores analógicos, e seus registros eram feitos por meio de cartas gráficas, conforme pode ser observado na figura 2.1. Isto tornava a coleta de dados muito complicada, pois era necessário colocar as cartas lado a lado, a fim de sincronizá-las, fazer a leitura da carta e registrar os dados em uma planilha em Excel. Este processo de coleta de dados também implicava em erros de leitura, levando a coleta de dados incorretos.




Figura 2.1 - Cartas gráficas unidades de registro

A fim de melhorar a coleta de dados e facilitar as análises, foi necessário transferir todos os controladores envolvidos no controle da torre, para um sistema digital de controle. Isto possibilitou melhora significativa na coleta dos dados de processo conforme pode ser observado na **Erro! Fonte de referência não encontrada..**




Figura 2.2 - Gráfico sistema digital de controle.

Após inseridas as variáveis de processo no histórico do sistema digital de controle foram selecionados o período de amostragem e o intervalo de tempo das amostras, a fim de criar uma base de dados que foi carregada no Matlab para as simulações da arquitetura de controle.

As variáveis que constituem a arquitetura de controle da torre de HCN e que foram transferidas para o sistema digital de controle (SDC) são: O controle de razão entre a água de processo e o vapor (S3), formados pelo FFRC-12002 que controla a vazão de água de entrada, e FIC-12001 que controla a vazão de vapor (S3) de entrada e o sinal do analisador de pH AI-12001 que monitora o pH da água que sai da torre.

2.3 Transferência dos controles do sistema analógico para o sistema digital

O processo de migração dos controladores analógicos para o sistema digital foi complicado, pois foi necessário detalhar o projeto de migração dos controles, o que envolveu a digitalização e elaboração de vários documentos, tais como memoriais descritivos de configuração e montagem, elaboração de folha de dados, além de atualização de *P&I* (fluxograma de engenharia) e fluxogramas de processo entre outros documentos.

A transferência do sistema mostrou-se complicada, pois o processo foi realizado com a unidade operando, tornado a tarefa complicada e arriscada. Algumas medidas de segurança foram tomadas para garantir a segurança das pessoas envolvidas no processo de migração e evitar possíveis contaminações do meio ambiente devido a vazamento de produtos químicos, tais como soda e gases tóxicos.

2.4 Configuração dos controles

Após migração das malhas de controle para o SDC, foi configurado um controlador PI para controlar o pH torre de HCN provisoriamente até que fosse definido qual seria a técnica de controle utilizado. Após tentar sintonizar o controlador, optou-se por deixar o controle em manual, pois o controlador não foi

capaz de manter o valor do pH dentro dos limites exigidos, sendo necessário intervenção do manual do operador.

2.5 Dados de teste

Para entender o conceito do controle de pH, os testes iniciais foram realizados com dados de pH coletados de um processo de neutralização, conforme mostrado na figura 2.3.




Figura 2.3 - Tanque de neutralização

Este processo de neutralização consiste de um tanque, onde são adicionados soda e ácido, no qual é usado um agitador para homogeneizar a solução. Na saída do tanque é monitorado o pH da solução, contudo a dinâmica deste processo é totalmente diferente, pois tanto o ácido como a soda apresentam concentrações constantes. Além de não apresentarem variações bruscas de carga, nas entradas, e nem na saída. Logo nesta etapa foi possível apenas observar a funcionalidade da técnica, que posteriormente seria utilizada.

2.6 Toolbox matlab

Inicialmente foram realizados testes usando o toolbox de redes neurais do Matlab R2010b. Nesta etapa, os dados do tanque de neutralização foram carregados no matlab com o objetivo de identificar o sistema. Os dados de processo do tanque

de neutralização que foram utilizados são a vazão de entrada de ácido, vazão de entrada de base e tendo como saída o valor do pH da solução no tanque. Na figura 2.4 são mostrados os dados de processo do tanque de neutralização.




Figura 2.4 - Dados de processo tanque de neutralização

A rede neural utilizada para identificação foi uma rede neural NARX, constituída por uma camada oculta com 10 neurônios e função de transferência tangente sigmoidal e por uma camada de saída com 1 neurônio e função de transferência linear. Na figura 2.5 é apresentado um diagrama em bloco da rede neural NARX.




Figura 2.5 - Rede neural NARX para identificação

Dos dados utilizados para identificação do processo, 70% foram para treinamento da rede, 15% para teste e 15% para validação.

Na figura 2.6 é apresentado o resultado do toolbox de redes neurais do Matlab.




Figura 2.6 - Resposta de um elemento de saída para uma série temporal

O resultado apresentado pela rede neural no processo de identificação mostrou-se satisfatório, logo uma arquitetura de controle com redes neurais, seria uma boa opção para controlar o pH da torre de HCN.

A arquitetura de controle neural proposta para o controle do pH é o controle adaptativo de modelo de referência (MARC) usando redes neurais. Esta arquitetura de controle possui duas redes neurais, sendo uma para identificação do processo e a outra para controle e modelamento da planta.

2.7 Simulações

Nas simulações do controlador adaptativo de modelo de referência (MRAC), foram utilizados os dados de vazão de água de entrada, vazão de entrada de soda e tendo como resultado o valor do pH da água de saída. Na figura 2.7 são apresentados os valores da vazão de entrada de água e o valor do pH da água de saída.

As simulações foram feitas utilizando com base no código do controlador MRAC disponível no matlab R2010b. No entanto o código disponibilizado foi adaptado para receber os dados de processo da torre de HCN. Primeiramente o código foi alterado para receber a matriz contendo os dados de processo, em seguida foi configurada a rede neural, ou seja, número de entradas, número de neurônio, número de camada ocultas, função de treinamento entre outros. Como a arquitetura de controle possui duas redes neurais foi necessário ajustar as dimensões das matrizes dos pesos das redes neurais.




Figura 2.7 - Dados de processo para simulação

Depois de configurado o controlador neural o programa foi executado a fim de treinar e testar as redes neurais que compõem a arquitetura de controle proposta.

3 CARACTERÍSTICAS DO CONTROLE DE pH

3.1 Conceito de pH

O pH é a medida mais usada para entender o estado de uma reação (Shinsky, 1967). No entanto o processo de neutralização do pH é altamente não linear devido a relação logarítmica entre a concentração de íons de hidrogênio $[H^+]$ e o nível do pH (Elarafi & Hisham, 2008). Esta característica impõe exigências excepcionais na rangeabilidade das válvulas de vazão e do sistema de controle (Shinsky, 1967).

3.2 Curvas de titulação

O que caracteriza o controle de pH é a relação entre a variável controlada e a vazão manipulada do reagente, chamada curva de titulação. Em laboratório, uma curva de titulação de uma solução pode ser determinada anotando-se o valor do pH da amostra após a adição de um reagente na solução. Isso deve ser feito se o controle de pH for aplicado a uma efluente de composição desconhecida. No entanto, é possível derivar a curva dada e a concentração de cada um dos componentes, e assim prever sua variabilidade (Shinsky, 1996).

A curva de titulação de pH, é a relação logarítmica do pH e da concentração dos íons de hidrogênio da solução, conforme mostrada na equação (3.1), que é expressa em unidades de normalidade, ou seja, gramas de íons por litro de solução:

$$pH = -\log[H^+] \text{ ou } [H^+] = 10^{-pH} \quad (3.1)$$

A ionização da água pura é dada pela equação (3.2):




Usando a constante de equilíbrio K_w igual a 10^{-14} a 25°C .

$$K_w = [H^+][OH^-] = 10^{-14} \quad (3.3)$$

O resultado do equilíbrio, da concentração de íon de hidroxila é relacionado com o pH medido:

$$[OH^-] = \frac{10^{-14}}{[H^+]} = 10^{pH-14} \quad (3.4)$$

O ponto neutro da água é onde os íons hidroxila e hidrogênio apresentam a mesma concentração, ou seja, apresentam $pH=7$. Ácidos fortes como o HCl (ácido clorídrico) e o HNO_3 (ácido nítrico), e bases fortes como NaOH (hidróxido de sódio) e KOH (hidróxido de potássio) ionizam-se completamente – todos os seus grupos de hidrogênio e hidroxila aparecem na forma ionizada na solução, portanto são mensuráveis por eletrodo de pH. Por exemplo, considere a adição de HCl e NaOH na água em concentrações x_A e x_B , respectivamente:



Balanceando-se a solução resultante em carga, temos:

$$[H^+] + [Na^+] = [Cl^-] + [OH^-] \quad (3.6)$$

Ácido e base completamente ionizados:

$$[H^+] + x_B = x_A + [OH^-] \quad (3.7)$$

Substituindo as equações (3.1) e (3.4) obtém-se a relação entre as concentrações de ácido e base e a solução de pH:

$$x_A - x_B = 10^{-\text{pH}} - 10^{\text{pH}-14} \quad (3.8)$$

Quando $x_a = x_b$ a solução é neutra, ou seja, $\text{pH}=7$. Para mudança de uma unidade no pH a diferença de concentração variada aproximadamente uma década (10). Na Figura 3.1 nota-se que a curva de titulação do HCl à concentração de 0,01 N é a que apresenta a queda mais acentuada.

Efetuar o controle na região neutra, pH entre 6 e 8, torna-se mais difícil, pois a neutralização esta ocorrendo em um intervalo mais afastado deste range.

Por exemplo, para uma solução entrando com $\text{pH}=5$ é necessário a adição de soda cáustica a uma concentração de $10^{-5} \text{ N} + /-10^{-6} \text{ N}$ ou com uma precisão de 1 parte em 10, um alvo fácil de acertar. Se o pH do afluente é 4, 10 vezes mais soda cáustica deve ser adicionada a fim de alcançar a neutralidade, mas para a mesma precisão absoluta, a qual agora é de 1 parte em 100. No entanto se o pH do afluente cair para 2, deve-se adicionara soda cáustico a uma concentração de $10^{-2} \text{ N} + /-10^{-6} \text{ N}$, a uma precisão de 1 parte em 10000. (A mesma precisão é necessária para a adição de ácido a uma solução básica pH 9, 10 e 12, respectivamente). Válvulas de controle, bombas dosadoras e medidores de vazão podem não ter a precisão necessária para malha de controle de pH aberta. Logo é necessário efetuar o controle em malha fechada, mas a exigência da precisão mostra a importância da utilização de válvula para com posicionadores para eliminar a zona morta.





Figura 3.1 - Curva de titulação de três ácidos comuns com soda

Bases e ácidos fracos ionizados incompletamente inclinam a curva de titulação na região neutra. Essa propriedade é conhecida como amortecedor (em inglês *Buffers*). O equilíbrio mostrado na equação (3.9) ocorre entre um ácido monoproticos fraco HA e seus íons e entre uma base monoproticos fraca BOH e seus íons: o prefixo mono indica que ambos têm apenas um íon para dar por molécula:



A concentração do ácido ou base não-ionizado varia com o pH em relação ao valor da sua constante de ionização:

$$[HA] = \frac{[H^+][A^-]}{K_A} \quad [BOH] = \frac{[B^+][OH^-]}{K_B} \quad (3.10)$$

A equação (3.10) pode ser reescrita usando o pH no lugar dos termos $[H^+]$ e $[OH^-]$, expressando assim as constantes de ionização (equilíbrio) K_A e K_B como sua base de logaritmos negativos pK_A e pK_B , respectivamente. Isso coloca as constantes de ionização nas mesmas condições como o pH:

$$[HA] = [A^-]10^{pK_A - pH} \quad [BOH] = [B^+]10^{pK_B + pH - 14} \quad (3.11)$$

No ponto onde $\text{pH} = \text{pK}_A$, o ácido é meio ionizado, isto é, a concentração de íons de A^- é igual à do ácido não-ionizado HA ; da mesma forma em $\text{pH} = 14 - \text{pK}_B$, a base é meio ionizada. A tabela 3.1 lista as constantes de ionização para ácidos fracos e bases mais comuns.

Acido	Equilíbrio	pK_A
Acido Acético	$\text{CH}_3\text{COOH} \rightleftharpoons \text{CH}_3\text{COO}^- + \text{H}^+$	4.75
Dióxido de Carbono	$\text{CO}_2 + \text{H}_2\text{O} \rightleftharpoons \text{HCO}_3^- + \text{H}^+$	6.25
	$\text{HCO}_3^- \rightleftharpoons \text{CO}_3^{2-} + \text{H}^+$	10.25
Fluoreto de Hidrogênio	$\text{HF} \rightleftharpoons \text{F}^- + \text{H}^+$	3.17
Sulfeto de Hidrogênio	$\text{H}_2\text{S} \rightleftharpoons \text{HS}^- + \text{H}^+$	7.0
	$\text{HS}^- \rightleftharpoons \text{S}^{2-} + \text{H}^+$	12.9
Acido Hipoclorídrico	$\text{HClO} \rightleftharpoons \text{ClO}^- + \text{H}^+$	7.5
Acido Sulfídrico	$\text{H}_2\text{SO}_4 \rightleftharpoons \text{HSO}_4^- + \text{H}^+$	-3
	$\text{HSO}_4^- \rightleftharpoons \text{SO}_4^{2-} + \text{H}^+$	1.99
Dióxido de Enxofre	$\text{SO}_2 + \text{H}_2\text{O} \rightleftharpoons \text{HSO}_3^- + \text{H}^+$	1.8
	$\text{HSO}_3^- \rightleftharpoons \text{SO}_3^{2-} + \text{H}^+$	6.8

Base	Equilíbrio	pK_B
Íon de Alumínio	$\text{AlO}_2^- + 2\text{H}_2\text{O} \rightleftharpoons \text{Al}(\text{OH})_3 + \text{OH}^-$	1.6
Amônia	$\text{NH}_3 + \text{H}_2\text{O} \rightleftharpoons \text{NH}_4^+ + \text{OH}^-$	4.75
Hidróxido de Cálcio	$\text{Ca}(\text{OH})_2 \rightleftharpoons \text{CaOH}^+ + \text{OH}^-$	1.40
	$\text{CaOH}^+ \rightleftharpoons \text{Ca}^{2+} + \text{OH}^-$	2.43
Etilanina	$\text{C}_2\text{H}_5\text{NH}_2 + \text{H}_2\text{O} \rightleftharpoons \text{C}_2\text{H}_5\text{NH}_3^+ + \text{OH}^-$	3.3
Hidróxido Férreo	$\text{Fe}(\text{OH})_2 \rightleftharpoons \text{FeOH}^{2+} + \text{OH}^-$	9.3
	$\text{FeOH}^{2+} \rightleftharpoons \text{Fe}^{3+} + \text{OH}^-$	11.5
Hidrazina	$\text{N}_2\text{H}_4 + \text{H}_2\text{O} \rightleftharpoons \text{N}_2\text{H}_5^+ + \text{OH}^-$	5.5
Hidroxilamina	$\text{NH}_2\text{OH} + \text{H}_2\text{O} \rightleftharpoons \text{NH}_3\text{OH}^+ + \text{OH}^-$	7.97
Hidróxido de Magnésio	$\text{Mg}(\text{OH})_2 \rightleftharpoons \text{MgOH}^+ + \text{OH}^-$	2.6

Tabela 3.1 - Constante de ionização de ácidos e bases

O ácido sulfúrico e o ácido fluorídrico são incluídos na tabela como ácidos fracos, apesar da capacidade para desidratar os hidratos de carbono e causticar vidro. Hidróxido de cálcio (CAL) é moderadamente forte, mas sua solubilidade limitada produz uma solução saturada com pH=12,3. A constante de ionização de bases, são expressas como pK_A , a qual é $14 - pK_B$. Note-se que a ionização do $FeOH^{2+}$ para íon férrico tem uma constante de ionização $pK_B=11,5$. O reverso desta reação Fe^{3+} para formar $FeOH^{2+}$ e H^+ , cujo pK_A é $14,5 - 11,5 = 2,5$. A constante pK_B 11,5 indica que hidróxido férrico é uma base fraca e que seu produto o íon férrico, é ácido moderadamente forte.

Um ácido fraco em concentração x_{AW} ou base fraca em concentração x_{BW} adicionados à uma solução contendo um ácido forte e base irá adicionar os seguintes componentes para a massa e equilíbrio de carga:

$$x_{AW} = [HA] + [A^-] \quad x_{BW} = [BOH] + [B^+] \quad (3.12)$$

Depois que os componentes são adicionados ao balanço, e substituindo-se na equação (3.11), temos:

$$x_A - x_B = 10^{-pH} - 10^{pH-14} - \frac{x_{AW}}{1 + 10^{pK_A-pH}} + \frac{x_{BW}}{1 + 10^{pK_A+pH-14}} \quad (3.13)$$

A equação (3.13) é uma expansão da equação (3.8) que inclui os componentes monoproticos fracos.

A Figura 3.1 contém a curva de titulação do ácido acético a 0,01 N com soda cáustica, resultando em uma inclinação mínima no ponto de amortecimento onde $pH = pK_A = 4.75$; neste ponto o ácido fraco é parcialmente neutralizado. O ponto neutro desta curva é na realidade quando $pH > 8$, porém o mais importante é que a inclinação da curva em $pH=7$ é um fator de 100 menor do que a curva de HCL.

A amônia é uma base fraca cuja constante de ionização é a mesma do ácido acético. No entanto a titulação da amônia com um ácido forte produz uma

curva que é o espelho da curva do ácido acético, com o ponto de amortecimento pH=9,25.

Ácidos dipróticos fracos e bases são muito comuns – alguns são mostrados na tabela 3.1 com duas constantes de ionização. O mais comum é o ácido carbônico mostrado como CaCO_3 .

A ionização do CO_2 se realiza em duas fases, com valores de pK_A de 6.35 e 10.25. Substituindo os últimos termos na equação (3.13), tem-se:

$$\dots - \frac{x_{Aw}(1 + 0.5 \times 10^{\text{pK}_{A2}-\text{pH}})}{1 + 10^{\text{pK}_{A2}-\text{pH}}(1 + 10^{\text{pK}_{A1}-\text{pH}})} + \frac{x_{Bw}(1 + 0.5 \times 10^{\text{pK}_{B2}+\text{pH}-14})}{1 + 10^{\text{pK}_{B2}+\text{pH}}(1 + 10^{\text{pK}_{B1}+\text{pH}-14})} \quad (3.14)$$

Naturalmente é possível adicionar qualquer número de dois agentes monopróticos e dipróticos, simplesmente adicionando um termo adequado para cada um na equação (3.14).

A terceira curva de titulação mostrada na figura 3.1 é de 0.01 N de CO_2 com adição de 50% a mais de HCL para mostrar o menor ponto da curva e exigir a adição da mesma quantidade de soda cáustica para a outra curva. Isto porque o valor da segunda constante pK_A é $\text{pH} > 7$, apenas metade do CO_2 é neutralizado no meio da escala. O menor valor de pK_A é de 6.35 é perto de $\text{pH}=7$, razão pela qual bicarbonatos são usados para amortecimentos de ácidos estomacais. Conseqüentemente, a presença de carbonatos na água e em águas residuais torna o controle de pH mais fácil. Usar Na_2CO_3 como reagente neutralizantes no lugar de NaOH eliminaria a maioria das oscilações na malha de pH, mas infelizmente requer duas vezes mais sódio o que não é rentável. O gás de dióxido de carbono pode ser usado como reagente ácido, mas tem a mesma limitação.

Exceto quando empregado como reagentes, os amortecedores geralmente são em concentrações consideráveis mais baixas do que as mostradas para o ácido acético e CO_2 na figura 3.1, mas podem aparecer combinados. A maioria dos íons metálicos como ferro, alumínio, cobre e zinco são amortecedores eficazes, fazendo controle do pH de água residuais, de processos que envolvem acabamento de

metais. Este é um tipo de controle relativamente simples e pode ser feito por meio de controlador linear. Mas um dos problemas no controle do pH de águas residuais provenientes de processos químicos é a variabilidade dos amortecedores. Os agentes de limpeza, tais como carbonatos, fosfatos, silicatos, sabonetes e detergentes são todos amortecedores, ou seja, agentes neutralizantes. E tendem a serem lançados em batelada no efluente. Uma malha de controlador de pH é ajustado para uma determinada condição de processo, entretanto se ocorrer uma mudança nas condições gerais do processo alterando significativamente o pH do efluente. Esta nova situação, completamente diversa daquela para a qual o controle foi ajustado impõe a necessidade de uma nova sintonia nos parâmetros do controlador. Um caso clássico é a neutralização do efluente da lavagem de leitos de troca iônica usados na desionização da água de alimentação de caldeira. No início do ciclo de lavagem o efluente é rico em amortecedores, que em seguida diminuem com o tempo. Portanto, o controlador de pH de águas residuais deve ser auto ajustável, bem como não-linear.

3.3 Controle de pH

O controle de pH é comum em processos químicos, petroquímicos e indústrias de biotecnologia. Por exemplo, o pH da água residual de processo enviado para a estação de tratamento de efluentes deve ser mantida dentro de limites ambientais rigorosas (Henson & Seborg, 1994).

A figura 3.2 mostra uma curva de titulação de pH no qual o ganho é máximo no ponto de ajuste (pH igual a 7) e diminui com o aumento do desvio em qualquer direção. Se o processo tem alto ganho dinâmico, mesmo a maior banda proporcional disponíveis no controlador pode não ser suficiente para manter o ganho do processo menor que 1,0. Isso fará com que a oscilação aumente deixando o processo instável. A malha de pH ficará oscilando indefinidamente - tipicamente pH entre 5 e 9 ou 4 e 10.




Figura 3.2 - O ganho da curva de titulação é o desvio do pH e causado por uma mudança na vazão reagente Δm

Embora em determinados processos, a concentração do pH varie de tempos em tempos - ocasionalmente até mesmo caindo a zero – devido a buffers, tais como, agentes de limpeza e íons metálicos que entram e saem na solução.

Durante o tratamento de águas residuais o pH pode encontrar-se em ambos os lados da neutralidade, o controlador pH deve manipular válvulas ácidas e cáusticas a fim de controlar a neutralização. No entanto, mesmo que seja pequena a zona morta entre as duas válvulas isso terá pouco resultado na atuação do controle, o que pode aumentar o consumo de ambos os reagentes, muito acima do mínimo necessário para neutralizar os resíduos.

Se a banda proporcional de um controlador linear de pH puder ser definida larga o suficiente para reduzir o ganho da malha abaixo de 1.0, o limite de atuação será extinto. No entanto, o ganho de controlador, pode ser tão baixo que a resposta às variações de carga é inaceitável. Na figura 3.3, pode ser observada a resposta do controlador linear de uma malha de pH após uma mudança de carga no processo. O ganho da malha é tão baixo no intervalo do pH entre 5 e 9, que a correção leva um longo tempo e é realizada principalmente pela ação de controle integral. Durante este tempo, a saída do controlador praticamente satura (*winds-up*), resultando de um grande *overshoot*. Isso resulta em um desempenho insatisfatório nas regiões longe do ponto de neutralização além do consumo excessivo de reagentes devido a oscilações no processo ou resposta lenta da variável de processo (Shinsky, 1996).

Por esta razão, controles de pH convencionais, como PID (Proporcional – Integral –Derivativo) ou técnicas de controle avançado baseado em teoria de sistemas lineares são ineficientes (Kang, Yoon, Yang e Yoon Seong, 2000).




Figura 3.3 - Malha de pH com controlador linear

Uma função não linear mostra-se muito eficaz no controle do pH de águas residuais. Na figura 3.4, pode ser observada a resposta de uma malha de pH controlada por um controlador não linear para a mesma mudança de carga no processo.




Figura 3.4 - Malha de pH com controlador não linear

Nota-se que as correções são satisfeitas se o pH do emissário (a jusante de tratamento biológico e sedimentação) permanece entre 6 e 9.

4 REDES NEURAIS

Redes neurais são sistemas paralelos distribuídos compostos por unidades de processamento simples, também conhecidos como nodos, que calculam determinadas funções matemáticas, normalmente não-lineares. Estas unidades são organizadas em uma ou mais camadas e interligadas por meio de conexões. Na maior parte dos modelos as conexões são associadas a pesos, que tem a função de armazenar o conhecimento representado no modelo, ponderando a entrada recebida por cada neurônio da rede. O funcionamento das redes neurais artificiais é inspirado no sistema biológico nervoso, assim como na natureza as conexões entre os elementos determinam a função da rede (Braga, Ludimir, & Carvalho, 2000).

Uma rede neural pode ser treinada para realizar funções particulares, ajustando os valores das conexões (pesos) entre os elementos. As redes neurais são ajustadas e treinadas para que uma determinada entrada atinja uma saída de destino específico. O ajuste da rede é realizado com base na comparação entre a saída e o alvo (*target*), até a saída da rede corresponde ao valor desejado (*target*). Geralmente muitos pares de entradas e alvos são necessários para treinar uma rede. A figura 4.1 mostra um modelo simplificado de uma rede neural.

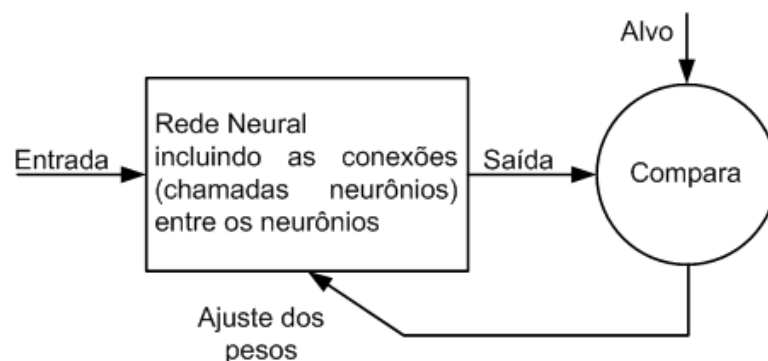


Figura 4.1 - Modelo de Rede Neural

As redes neurais geralmente são treinadas a fim de executar funções complexas em várias áreas da engenharia, tais com, reconhecimento de padrões, identificação, classificação, visão, e sistemas de controle.

Uma característica importante de uma rede neural treinada, é que nenhum conhecimento do processo que está sendo treinado para simular é necessário. Uma vez que aprender com a experiência ao invés de programação, a sua utilização pode ser considerada como uma abordagem Black Box (Burns, 2001).

4.1 Modelo de Neurônio

No neurônio biológico, canais localizados nas sinapses recebem os sinais de entrada permitindo a entrada e saída de íons. Devido à integração dos sinais de entrada um potencial de membrana é gerado, isto irá determinar se o neurônio produzirá um sinal de saída ou não. O potencial de ação resulta na liberação de neurotransmissores na sinapse sempre que o potencial de membrana for maior que determinado limiar. Este processo biológico que ocorre nas sinapses é representado por um peso associado (Zuben & Attux, 2007).

Em 1943 McCulloch e Pitts propuseram um modelo de neurônio, figura 4.2, para redes neurais artificiais, no qual o neurônio está executando uma função lógica.




Figura 4.2 - Neurônio de McCulloch e Pitts

Onde:

$x_1, x_2 \dots x_n$ – Sinais de entrada

w_1, w_2 e w_3 – Pesos associados às entradas

Σ - Função de ativação

θ – Limiar ou *threshold* do neurônio

y – Sinal de saída

No modelo proposto por McCulloch e Pitts, também conhecido com modelo MCP. Os nodos em cada camada da rede disparam sincronamente, ou seja, todos os nodos são avaliados ao mesmo tempo. No entanto, em sistemas biológicos não existe um mecanismo para sincronizar as ações dos nodos. Nem existe restrição para que as suas saídas sejam ativadas em tempos discretos como no modelo MCP. Outro ponto importante é que o valor da próxima saída dos nodos biológicos depende muito das ativações dos estados precedentes, pois até mesmo os neurotransmissores liberados anteriormente demoram algum tempo para se recombinarem, influenciando assim as ativações seguintes. O modelo MCP original apresenta algumas limitações:

1. Com redes MCP que possuem apenas uma camada, é possível implementar apenas funções linearmente separáveis.
2. Pesos negativos são mais adequados para representar disparos inibidores.
3. O modelo foi proposto com pesos fixos, não-ajustáveis.

4.2 Neurônio Simples

O modelo básico de um neurônio artificial consiste das sinapses, as quais são caracterizadas pelos pesos associados, a junção somadora e a função de ativação (ou transferência). O modelo básico de um neurônio artificial é mostrado na figura 4.3.




Figura 4.3 - Neurônio Simples

Primeiramente, a entrada P é multiplicada pelo peso w resultando no produto wp . A função somadora soma o limiar (bias) b , resultando na entrada n ($n = wp + b$) da rede neural. O limiar (*bias*) tem a função de aumentar ou diminuir a influência do valor da entrada para a ativação do neurônio. Finalmente, a entrada da rede passa pela função de ativação f , que geralmente tem o propósito de limitar a saída do neurônio e/ou introduzir não linearidade no modelo resultante.

Para muitos tipos de redes neurais, é o produto da função peso vezes a entrada, mas outras funções peso (como por exemplo, a distância entre o peso e a entrada, $|wp|$) podem ser usadas. A função de entrada da rede mais comum é a somatória das entradas ponderadas com o limiar (bias), mas outras operações como multiplicação podem ser usadas.

Note-se que w e b são parâmetros ajustáveis do neurônio. A idéia central de uma rede neural é que os parâmetros possam ser ajustados de modo que a rede apresente o comportamento desejado. Logo, é possível treinar a rede para fazer um trabalho específico, ajustando os pesos e o limiar (bias).

4.3 Funções de ativação

O modelo proposto por McCulloch e Pitts, foi usado como base para o desenvolvimento de outros modelos de neurônios, os quais permitem a produção de qualquer saída, que não necessariamente zero ou um, com o uso de diferentes funções de ativação (Braga, Ludimir, & Carvalho, 2000). Algumas funções de ativação são apresentadas na figura 4.4.




Figura 4.4 - Funções de ativação

As funções de ativação mais comuns são: a função linear e a função sigmoide. Estas funções estão presentes na última camada das redes neurais multicamadas, e são usadas como funções de aproximação. A figura 4.5 mostra uma função de ativação linear.




Figura 4.5 - Função de ativação linear

A função de ativação linear mostrada na figura 4.6 é definida pela equação (4.1).

$$y = ax \quad (4.1)$$

Onde a é um número real que define a saída linear para os valores de entrada, y é a saída e x é a entrada.

A função sigmoidal, ilustrada na figura 4.6, é uma função semilinear. É possível definir várias funções sigmoidais.




Figura 4.6 - Função de ativação sigmoidal

As funções sigmoidais são encontradas na construção de diversos modelos nas mais variadas áreas. Umas das funções sigmoidais mais importantes é a função logística definida pela equação (4.2):

$$y = \frac{1}{1 + e^{\frac{-x}{T}}} \quad (4.2)$$

onde a suavidade da curva da curva é determinada pelo parâmetro T .

4.4 Neurônio com vetor de entrada

A um neurônios simples podem ser aplicado entradas vetoriais, conforme mostrado na figura 4.7. E um neurônio com vetor de entrada de R -elemento conforme mostrado na equação (4.3).

$$p_1, p_2, \dots, p_R \quad (4.3)$$

são multiplicados pelos pesos:

$$w_{1,1}, w_{1,2}, \dots, w_{1,R} \quad (4.4)$$

os valores ponderados são somados, resultando wp , que é o produto escalar da matriz w (matriz linha) e o vetor p .




Figura 4.7 - Neurônio com Vetor de Entrada

O neurônio mostrado na figura 4.7 tem um limiar (*bias*) b , o qual é somado às entradas ponderadas para formar a entrada n da rede. Matematicamente a saída do neurônio pode ser representada pela equação (4.5).

$$a_k = f(n_k) = f\left(\sum_{j=1}^R w_{kj} p_j + b_k\right) \quad (4.5)$$

4.5 Arquitetura de redes

As redes neurais utilizam arquiteturas padronizadas, que são projetadas para resolver algumas classes de problemas.

A definição da arquitetura de uma rede neural é um parâmetro importante na sua concepção, uma vez que ela restringe o tipo de problema que pode ser tratado pela rede. Por exemplo, redes com uma camada de nodos MCP, só conseguem resolver problemas linearmente separáveis. Já as redes recorrentes, são mais apropriadas para resolver problemas envolvendo processamento temporal.

Os seguintes parâmetros fazem parte da definição da arquitetura da rede neural:

- Número de camadas da rede.
- Número de nodos em cada camada.
- Tipo de conexão entre os nodos.
- Topologia da rede.

4.5.1 Rede neural com uma camada de neurônios

Esta arquitetura de rede neural é formada por uma camada de entrada e uma camada de saída, conforme mostrado na figura 4.8. Nesta arquitetura de rede, cada elemento do vetor de entrada p é conectado a um neurônio da entrada através do peso da matriz W . Cada neurônio tem uma função de soma que reúne suas entradas ponderadas e o seu limiar (*bias*) formando sua própria saída $n(i)$. Os vários elementos $n(i)$ formam o vetor de entrada n da rede.




Figura 4.8 - Rede neural com uma camada de neurônios

Finalmente, as camadas de saídas dos neurônios formam o vetor coluna a . A expressão da saída da rede pode ser observada na equação (4.6).

$$a = f(Wp + b) \quad (4.6)$$

É possível criar uma única camada de neurônios com diferentes funções de transferência simplesmente agrupando duas ou mais redes em paralelo, conforme mostrado anteriormente. As redes teriam as mesmas entradas, e cada rede criaria suas saídas.

Os elementos do vetor de entrada entram na rede por meio da matriz de pesos W , conforme mostrado abaixo.

$$W = \begin{bmatrix} w_{1,1} & w_{1,2} & \cdots & w_{1,j} \\ w_{2,1} & w_{2,2} & & w_{2,j} \\ \vdots & & \ddots & \vdots \\ w_{i,1} & w_{i,2} & \cdots & w_{i,j} \end{bmatrix}$$

Na matriz W , os índices das linhas indicam qual é o neurônio ou entrada de origem, e os índices das colunas indicam qual é o neurônio de destino. Logo na figura 4.3, o índice $w_{1,2}$ indica o peso da conexão sináptica da entrada 2 para o neurônio 1.

Esta arquitetura de rede é conhecida com *feedforward*, pois a propagação do sinal ocorre apenas da entrada para a saída, ou seja, só no sentido positivo (Zuben & Attux, 2007).

4.5.2 Rede neural multicamadas

Uma rede neural multicamadas tem uma ou mais camadas intermediárias interconectadas. Com a adição de camadas intermediárias é possível aumentar a capacidade de processamento de uma rede feedforward.

O processamento realizado por cada nodo em uma rede neural multicamadas, é definido pela combinação dos processamentos realizados pelos nodos da camada anterior. À medida que se segue da primeira camada intermediária em direção à camada de saída, aumenta a complexidade das funções

de transferências implementadas na rede. A figura 4.9 mostra uma rede neural multicamada com três camadas.

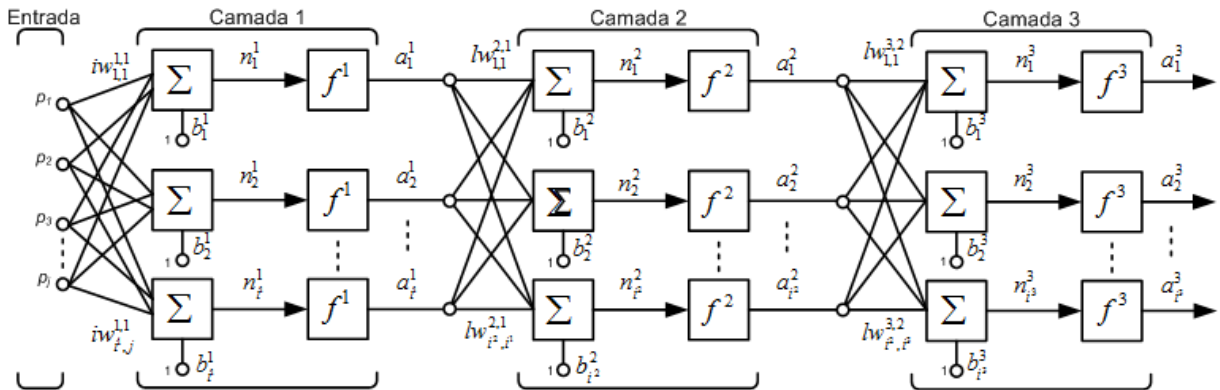


Figura 4.9 - Rede neural multicamadas

É comum diferentes camadas terem números diferentes de neurônios. Cada neurônio possui uma entrada de limiar (bias), para a rede apresentada na figura 4.9 o limiar é constante e igual a 1.

Cada camada de uma rede multicamadas desempenha um papel diferente. A camada que produz a saída de rede é chamada de camada de saída. Todas as outras camadas são chamadas de camadas ocultas. A rede de três camadas mostrada na figura 4.9 tem uma camada de saída (camada 3) e duas camadas ocultas (camada 1 e a camada 2).

4.5.3 Redes neurais recorrentes

Redes neurais recorrentes são baseadas no trabalho de Hopfield e contêm ao menos um laço de realimentação. A figura 4.10 mostra uma única camada totalmente conectada à rede recorrente com um atraso de (z^{-1}) no laço de alimentação (Burns, 2001).




Figura 4.10 - Rede neural recorrente

Se na figura 4.10, as entradas ocorrem no tempo (KT) e as saídas são previstas no tempo $(K + 1)T$, então a rede neural poder ser representada em uma matriz na forma:

$$y(K + 1)T = W_1 y(KT) + W_2 x(KT) \quad (4.7)$$

4.6 Tipos de conexões entre os neurônios

Os nodos podem apresentar conexões do tipo, feedforward ou acíclica. Nestas conexões a saída de um neurônio na i -ésima camada da rede não pode ser usada como entrada de nodos em camadas de índice menor ou igual a i , conforme mostrado na figura 4.11.




Figura 4.11 - Rede feedforward ou acíclica

As conexões entre os nodos também podem ser do tipo feedback, ou seja, com realimentação. A saída de um neurônio na i -ésima camada da rede é usada como entrada de nodos em camadas de índice menor ou igual a i , figura 4.12.




Figura 4.12 - Rede feedback ou cíclica

Redes neurais com arquitetura conforme mostrada na figura 4.12 (a) cuja saída é ligada à entrada comportam-se como autômatos reconhecedores de cadeias, onde a saída que é realimentada fornece o estado do autômato. Ou ainda redes neurais com arquitetura conforme mostrado na figura 4.12 (b), onde todas as ligações são cíclicas, a rede é conhecida como auto-associativa. Estas arquiteturas de rede associam um padrão de entrada com ele mesmo, são particularmente úteis para recuperação ou "regeneração" de um padrão de entrada.

5 REDES APLICADAS A CONTROLE

Redes neurais artificiais representam uma alternativa atraente para modelar e controlar de processos industriais, pois podem aprender as características não-lineares do processo a partir dos dados de entrada e saída. Varias arquiteturas de controladores utilizando redes neurais são propostas, tais como: IMC (*Internal Model Control*), MPC (*Model Predictive Control*) e o MRAC (*Model Reference Adaptive Control*) (Douratsos & Gomm, 2007).

No MRAC são implementadas duas redes neurais, sendo uma rede neural atuando como controlador, e a outra rede neural podendo ser empregada como modelo do processo. Esta última arquitetura oferece informações de processo com um algoritmo de otimização o qual é responsável pela adaptação dos parâmetros do controlador (Douratsos & Gomm, 2007).

5.1 Redes neurais dinâmicas

Redes neurais podem ser classificadas como estáticas e dinâmicas. Redes estáticas (feedforward), não têm elementos de realimentação (feedback) e não possuem atraso; a saída é calculada diretamente a partir da entrada por meio de conexões feedforward. Nas redes dinâmicas, figura 5.1, a saída depende dos estados atuais e anteriores das entradas, saídas ou ainda do estado da rede.

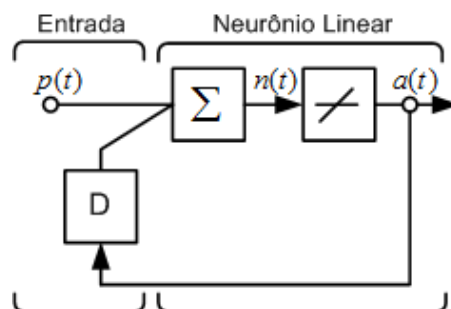


Figura 5.1 - Rede neural dinâmica simples

A saída da rede dinâmica é dada pela equação (5.1)

$$a(t) = iw_{1,1}p(t) + lw_{1,1}a(t - 1) \quad (5.1)$$

As principais diferenças no projeto de uma rede neural dinâmica ocorrem porque as entradas para as redes dinâmicas são seqüências no tempo. Isso resulta em alguns procedimentos adicionais de inicialização antes do treino ou simulação de uma rede dinâmica.

5.2 Aplicação Redes Neurais Dinâmicas

Redes dinâmicas são geralmente mais eficazes que as redes estáticas, pois as redes dinâmicas têm memória que podem ser treinados para aprender tanto seqüencialmente como padrões variantes no tempo. As redes neurais dinâmicas têm aplicações em diversas áreas, tais como: previsão de mercados financeiros, sistemas de comunicação, detecção de fase em sistemas de potência, classificação e detecção de falhas, reconhecimento de voz, e até mesmo na previsão da estrutura da proteína em genética. Uma das principais aplicações das redes neurais dinâmica é em sistemas de controle, ou ainda em filtros adaptativos.

5.3 Controle adaptativo de modelo de referencia.

Como mencionado anteriormente, no controle adaptativo de modelo de referência (MRAC), são empregadas duas redes neurais, sendo a primeira destinada para controle e a segunda empregada como modelo do processo. Logo, fornecendo dados de entrada e saída adequados, a rede neural pode modelar processos dinâmicos não lineares (Burns, 2001).

A rede neural destinada para modelamento do processo fornece informações para um algoritmo de otimização para auxiliar na adaptação dos

parâmetros do controlador. Uma vantagem do regime MRAC é que o controlador é continuamente adaptativo e pode, portanto, acompanhar variações de processo que muitas vezes ocorrem no sistema real.

Considerando o modelo da planta dada pela equação (5.2):

$$\dot{y}(t) + f[y(t)] = u(t), \quad t \geq 0 \quad (5.2)$$

onde o sinal de saída do processo é dado por $y(t)$, e o sinal de entrada do processo é dado por $u(t)$, e $f: R \rightarrow R$ é a função estática não-linear desconhecida que é continuamente diferenciável. Seja um sistema de modelo de referência linear estável e contínuo no tempo dado pela equação (5.3):

$$\dot{y}_m(t) + a_m y_m = k_m r(t), \quad t \geq 0 \quad (5.3)$$

onde $y_m(t)$ é o sinal de saída, $r(t)$ é o sinal de entrada de referência, e $a_m > 0$, $k_m > 0$.

O objetivo de um controlador modo de referência adaptativo (MRAC) é obter regras de controle para $u(t)$, e regras de atualização dos parâmetros do controlador, de modo que uma ou mais variáveis da planta sejam mantidas dentro de limites pré-determinados, e o controle de malha fechada apresente o desempenho especificados pelo modelo de referência. Ou seja, o objetivo é projetar um controlador que calcule o sinal de ação de controle, de tal forma que o sistema de controle responde dinamicamente como especificado pelo modelo de referência. Isto pode ser expresso em termos matemáticos como se segue.

Dada uma planta com entrada $u(t)$, e saída $y(t)$ dada pela equação (5.2), e um modelo de referência estável especificado pela entrada $r(t)$ e saída $y_m(t)$ conforme equação (5.3) com sinal de entrada de referência $r \in L_\infty$. Logo, o objetivo é determinar uma regra de controle $u(t)$, para todo $t > 0$ e uma regra de atualização dos parâmetros do controlador de forma que:

$$\lim_{t \rightarrow \infty} \|y(t) - y_m(t)\| \leq \epsilon \quad (5.4)$$

para uma constante especificada $\varepsilon > 0$.

Assumindo que a_m , k_m , e $r(t)$ foram escolhidos de tal forma que a trajetória desejada $y_m(t)$ seja obtido para a saída $y(t)$. A regra de controle proposto tem a seguinte forma:

$$u(t) = -a_m y(t) + k_m r(t) + N_f[y(t), w(t)] = \theta^T \phi(t) \quad (5.5)$$

Onde $N_f(.,.)$ é implementado usando uma rede neural RBF ou um rede feedforward, para aproximar a função $f(.)$, w é o vetor de parâmetros da rede neural ($w \in R^p$) e $\theta(t) = [a_m, k_m, 1]^T \in R^3$ é o vetor das constantes de parâmetros, e $\phi(t) = [-y, r, N_f]^T \in R^3$ é o vetor de funções. O vetor w representa os parâmetros do controlador neural a ser ajustado ($w \in R^n$), e $\phi(t) = [-y, r, N_f]^T \in R^3$ é vetor de funções. O vetor w representa os parâmetros do neuro controlador a ser ajustado, figura 5.2.

Definindo o erro do sinal como

$$e(t) \triangleq y(t) - y_m(t).$$

Quando do controlador neural representa exatamente a função $f(\cdot)$, ou seja, quando $N_f[y(t), w(t)] = f[y(t)]$ para todo t , a equação de malha fechado do sistema, em termos do erro do sinal, é obtida substituindo a equação (5.3) e a equação (5.5) na equação (5.2)

$$\dot{e}(t) + a_m e(t) = 0 \quad (5.6)$$

Note que a equação (5.6) representa o erro do sistema linear com um único ponto de equilíbrio na origem, e este é assintoticamente estável desde que $a_m > 0$. Portanto, a saída $y(t)$ segue o modelo $y_m(t)$, ou seja, $e(t) = y(t) - y_m(t) \rightarrow 0$ com $t \rightarrow \infty$.

Considerando o erro de aprendizagem da rede neural, ou seja, aproximando o erro na representação da função $f(\cdot)$ por uma rede neural, dada por:

$$\Delta(y, w) \triangleq N_f[y(t), w(t)] - f[y(t)] \quad (5.7)$$

Substituindo as equações (5.3), (5.5) e (5.7) na equação (5.2), a equação de malha fechada do sistema é dada por:

$$\dot{e}(t) + a_m e(t) = \Delta(y, w) \quad (5.8)$$

Note que na equação (5.8) o erro de aprendizado tende a zero, ou seja, quando $N_f \rightarrow f$, o erro do controle $e(t)$ também tende a zero. Definindo os parâmetros dos pesos da rede neural como $\hat{w} = w - w^*$, onde w^* é o vetor de parâmetros ótimos correspondente ao erro mínimo global da rede que minimiza $|\Delta(y, w)|$, ou seja, o valor mínimo de $|\Delta(y, w)|$ que pode ser alcançado é $|\Delta(y, w^*)|$ (Patiño & Liu, 2000).

A arquitetura de um controlador com base no modelo de controle adaptativo de referencia é mostrado na figura 5.2. Esta arquitetura de controle é constituída pelo controlador e adaptador que constituem o controlador neural, modelo de referencia e o processo. O sistema possui uma malha de realimentação que inclui o processo e o controle, e outra malha de realimentação relacionada com a adaptação dos parâmetros do controlador.

O controle neural fornece o sinal de controle $u(t)$ para o processo a fim de manter a saída do processo $y_p(t)$ o mais próximo possível da saída desejada $y_m(t)$ especificada pelo modo de referencia. O erro $e(t)$ entre o modelo de referencia e a saída do processo é usado pelo adaptador para ajustar os parâmetros do controlador.

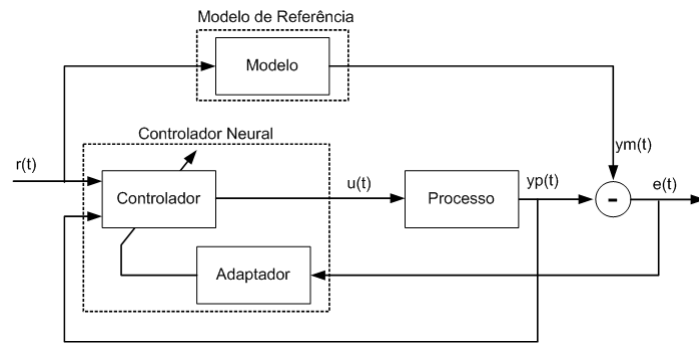


Figura 5.2 - Controle adaptativo de modelo de referência

O modelo de referencia representa uma parte do projeto na estratégia do MRAC, o qual define o desempenho exigido pelo sistema de malha fechada, pois é responsável por especificar o tempo de subida, tempo de estabilização, overshoot entre outras características. O modelo de referencia deve ser escolhido cuidadosamente para que o desempenho exigido possa ser alcançado pelo sistema de malha fechada. No MRAC linear, esta estrutura normalmente depende de uma determinada estrutura do modelo de processo.

O controle de modelo de referência pode apresentar tanto o comportamento linear ou não linear, isto é representado por um conjunto de parâmetros ajustados, e a sua estrutura deverá ser escolhido para permitir identificação perfeita em condições ideais (Douratsos & Gomm, 2007).

6 Descrição do processo

6.1 Unidade de gaseificação

O processo consiste basicamente na oxidação parcial de hidrocarbonetos do resíduo asfáltico sob pressão e em presença de oxigênio e vapor; esta reação é acompanhada de chama. Na figura 6.1 é apresentado um diagrama em bloco onde pode ser visualizado o processo de gaseificação.

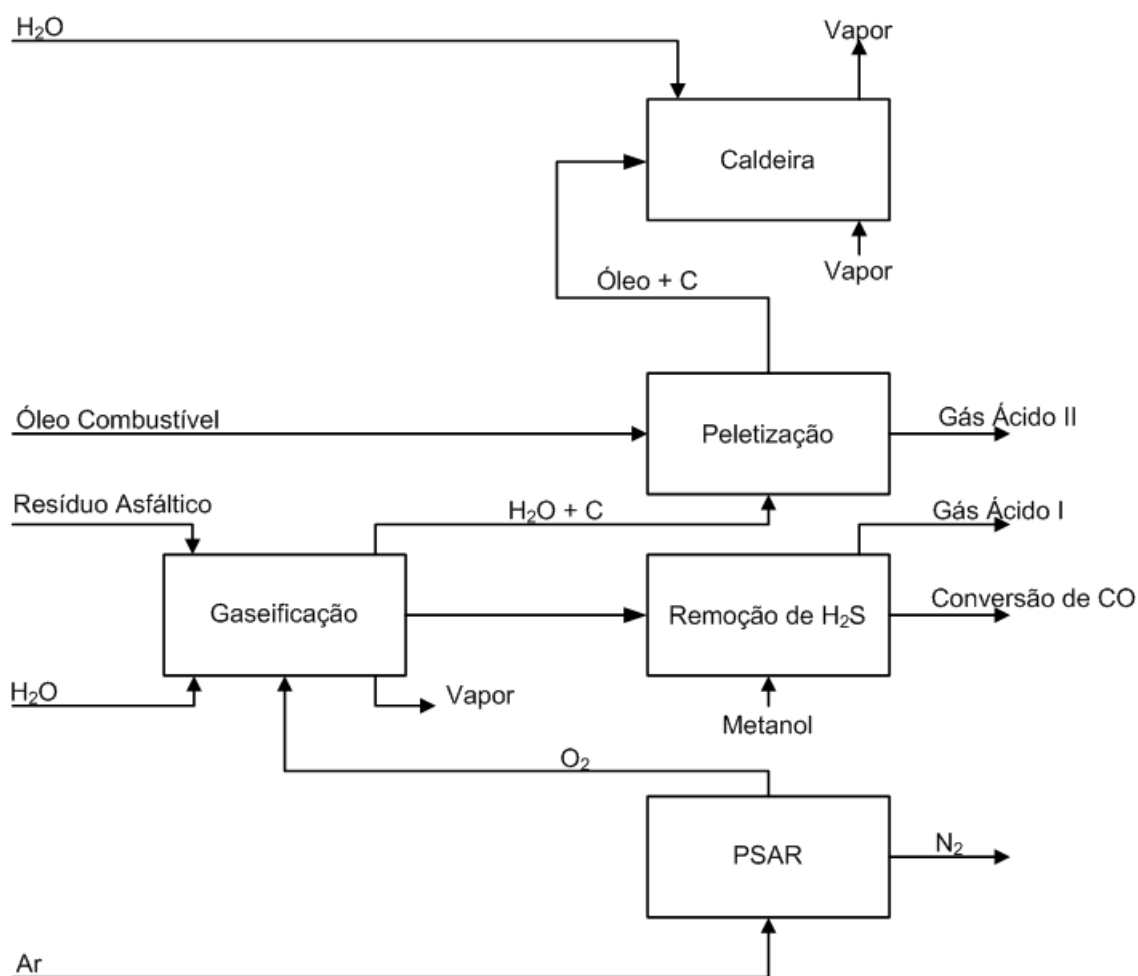




Figura 6.1 - Diagrama em bloco gaseificação

As reações de processo podem ser representadas como mostrado nas equações (6.1) e (6.2):



A reação de gaseificação é exotérmica, realizando-se a, aproximadamente a uma pressão de 60 Bar e a temperatura de 1400°C. Os componentes gasosos formados reagem com os produtos da combustão do óleo para dar uma mistura gasosa cuja composição final consiste, principalmente, de CO e H₂.

A fim de manter o processo de combustão e de craqueamento do óleo na razão desejada, é essencial não somente misturar os reagentes na razão definida, como também misturá-los com um agente moderador, neste caso vapor. Nestas condições a gaseificação dá uma quantidade definida de carbono formado.

6.2 Recuperação de calor

O resíduo é liberado do parque de tanques e alimenta as bombas de alta pressão. Antes de entrar no reator o óleo é aquecido nos pré-aquecedores de alimentação, a fim de se ter uma viscosidade tal que seja possível a atomização nos queimadores do reator.

Cada reator é provido de uma caldeira recuperador de calor e um economizador, nos quais os efluentes do reator são resfriados. A recuperação de calor é feita gerando vapor a pressão de 103 Bar, resfriando assim os efluentes do reator. Os efluentes são ainda mais resfriados nos economizadores, aquecendo a água de alimentação da caldeira recuperadora de calor. Os gases do reator e as partículas de carbono formado são, então, introduzidos em três tubos paralelos de resfriamento, onde são ainda mais resfriados até abaixo de seu ponto de orvalho e também são lavados por borrifamento de água proveniente do fundo da lavadora, por meio da bomba de circulação da lavadora de carbono. Esta mistura vai então, para os separadores de carbono, onde a lama de carbono é separada, indo por

gravidade, para o tanque de lama, o qual possui capacidade suficiente para servir como tanque intermediário durante possíveis problemas operacionais da unidade de recuperação de carbono.

Os gases deixando os três reatores os três recuperadores de carbono são combinados para formar uma corrente única, a qual é resfriada em outro pré-aquecedor de água de alimentação de caldeira, sendo enviado à lavadora.

A lavadora primeiramente é usada para resfriar os gases e, em segundo para remover as partículas de carbono ainda presentes nos gases efluentes dos reatores. Os gases brutos lavados saem pelo topo da lavadora e vão para a unidade recuperação de H_2S . A lama que sai pelo fundo da lavadora, vai para a unidade de recuperação de carbono via tudo de *quench*.

6.3 Unidade de recuperação de carbono

Na unidade de recuperação de carbono o carbono é separado da lama carbono, a água limpa é então re-circulada para o processo como água de retorno e parte desta água é enviada para o filtro de areia e em seguida para a torre de esgotamento de HCN. Além disso na unidade de recuperação de carbono os pellets formados são re-misturados com óleo combustível para formar mistura óleo-carbono, que é enviada para ser usado na caldeira auxiliar como combustível. Na figura 6.2 é mostrado um fluxograma da unidade de recuperação de carbono.



A lama de carbono vinda dos separadores de carbono no estágio de remoção de carbono é transferida para o tanque de lama. Este tanque tem suficiente capacidade para servir como “pulmão” durante possíveis problemas operacionais com a unidade de recuperação de carbono.

Os vapores e gases dissolvidos na lama de carbono são separados no tanque de lama 12-2011 e resfriados no condensador de topo do tanque de lama 12-2101 para uma temperatura de 56 °C por meio de aquecimento da água de alimentação de caldeira. A água condensada é separada no separador de condensado do topo do tanque de lama 12-2301 e finalmente enviada a esgotadora de HCN 12-2211 via tubo coletor de água 12-2011. Os gases não condensáveis são enviados para a unidade 21 através do soprador do gás ácido II 12-1010 ou para *flare* quente quando necessário.

O tanque de lama possui uma serpentina de aquecimento, a qual é aquecida com vapor saturado a pressão de 3 Bar (S3), isto ajuda no esgotamento dos componentes gasosos além de manter a temperatura constante. Para um esgotamento adicional dos componentes gasosos pela redução parcial de sua pressão parcial, o vapor saturado (S3) também pode ser introduzido, de forma que praticamente nenhum gás será liberado quando a água de fuligem é expandida dentro das máquinas de peletização.

Nos peletizadores a lama de carbono entra em contato com óleo combustível para formar pellets, que posteriormente são separados da água por meio de peneiras vibratórias. Os pellets de carbono que saem das peneiras vibratórias caem por gravidade no interior do misturador 12-1301-01/06.

Os pellets de carbono e óleo combustível são misturados no misturador helicoidal formando uma mistura óleo/pellets que cai por gravidade da saída do misturador indo para os tubos coletores 12-2013-01/02. Esta mistura vinda do tubo coletor será prensada no homogeneizador 12-1314-01/02 através de fenda de 30 microns, produzindo uma mistura óleo-carbono que é transmitida por meio da bomba

de transferência de óleo-carbono 12-1108-01/06 para queima na caldeira auxiliar (via tanque de óleo-carbono 05-2003).

Água livre dos pellets de carbono passa das peneiras vibratórias para os receptores de água de retorno. A maior parte da água é transferida através do filtro da água de retorno 12-2303-01/06 e por meio da bomba de água de retorno 11-1105-01/06 para o resfriador à ar da água de retorno 11-2107 e retornando para a lavadora de carbono 11-2202.

No caso de partida ou quando acontecem anormalidades na unidade de recuperação de carbono e nenhuma pequena quantidade de água de retorno é disponível para a lavadora, a água de caldeira no resfriador de água de reposição 12-2104, será adicionada para a linha de sucção da bomba de água de retorno. A quantidade de água adicionada será indicada por um medidor de vazão na linha de água de caldeira. O uso de água de caldeira mostra sempre que não existe estabilidade dentro da unidade de recuperação de carbono devido a:

- Vazamento na resfriador à ar da água de circulação da lavadora de carbono 11-2106 e/ou
- Processo instável da água – fuligem.

Os pellets de carbono sobrenadantes e os submersos presentes no receptor de água de retorno são transferidos juntos com água para o vaso aglomerados flutuantes 12-2008 e pela bomba de pellets submersos 12-1111-01/06 são transferidos para a peneira de finos 12-1415.

Os pellets coletados nesta peneira fina são transferidos de volta para o misturador 12-1301-01/06 ou para os depósitos de aglomerados. A água filtrada retorna pra os receptores de água de retorno.

O excesso de água dos receptores de água de retorno, condensado do topo do tanque de lama, água impura da unidade 13 e água residual da unidade 14 são

coletados no tubo coletor de água 12-2011 e pela bomba de alimentação da esgotadora de HCN 12-1110-01/06 passam através do filtro de areia 12-2310-01/06 e o filtrado é alimentado a esgotadora de HCN, conforme mostrado na figura 6.2.

Na esgotadora, cianeto de hidrogênio (HNC) e sulfeto de hidrogênio (H₂S) são quase totalmente removidos pelo aquecimento da água e esgotamento com vapor saturado de 3 Bar. Contudo não é possível remover a amônia da água em meio ácido, para isso seria necessário que a torre opera-se a baixa temperatura, o que não é possível. A torre esgotadora opera em torno de 120°C, isto possibilita que seja removido metanol, HCN e outros gases voláteis que são esgotados a quente.

Para solucionar esse problema a solução encontrada foi a injeção de soda no interior da torre, a fim de manter o meio básico, pH entre 10,5 e 11, o que possibilita a remoção da amônia com a torre operando em alta temperatura. A injeção de soda foi o meio mais prático de resolver o problema, e através da quantidade de soda injetada é controlado o pH (potencial hidrogeniônico) no efluente. A soda é injetada no 12º prato da coluna 12-2201-01(no meio) e na 12-2201-06 a soda é injetada próxima a entrada de carga, pois nesse ponto os outros gases já foram removidos, só restando a amônia, por isso a injeção no topo é desnecessária. O acompanhamento do pH no efluente é feito pelo AR-12001. O controle automático de injeção de soda é feito pelo AIC-12001 que atua nas bombas 12-1117-01 e 12-1117-06, dependendo da qual estiver selecionada para receber sinal de controle.

A bomba de circulação da esgotadora 12-1114-01/06 tem a função de repor a água que desce pelas bandejas ao topo da torre após ter sido resfriada de 95 a 55 °C no resfriador de circulação da esgotadora 12-2103.

Os gases efluentes desta torre são conduzidos a caldeira auxiliar para serem queimados. A água do fundo da torre é resfriada no resfriador á ar do excesso de água 12-2102 para uma temperatura de aproximadamente 40 °C antes de ser enviada ao limite de bateria ou ser coletada na parte inferior do tanque de lama 12-2001. A água filtrada, armazenada na parte inferior do tanque de lama é transferida

pela bomba de contra lavagem do filtro 12-1112-01/06 para os filtros de areia para contra lavagem. A água de contra lavagem e as partículas de carbono que são arrastadas do filtro são coletadas pelas bombas de transferência de lama 12-1113-01/06 para o tanque da unidade de recuperação de carbono.

7 RESULTADOS E DISCUSSÕES

A arquitetura de controle empregada no controle do pH da água da torre esgotadora de HCN, foi o controle adaptativo de modelo de referência usando redes neurais. Na figura 7.1 é mostrado o diagrama de blocos da arquitetura de controle proposta.

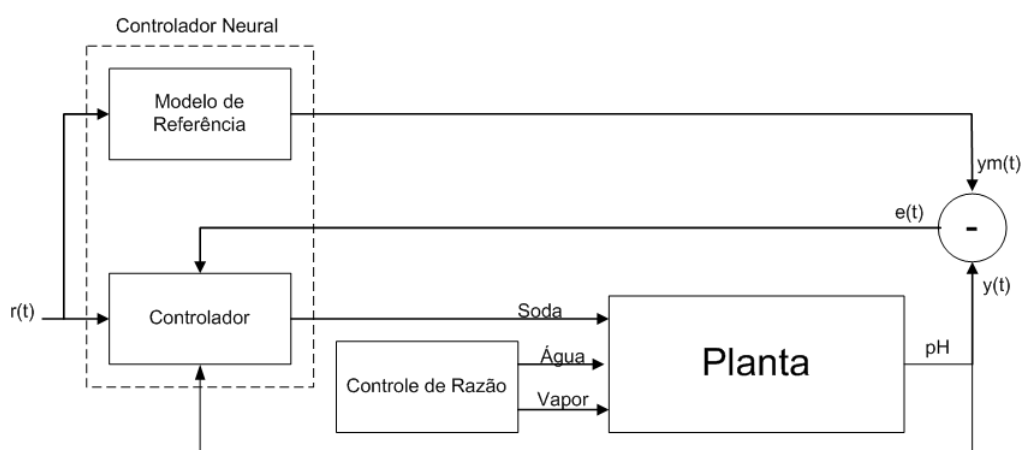


Figura 7.1 - Arquitetura de controle proposta para torre de HCN

Nesta arquitetura de controlador são usadas duas redes neurais, na qual uma rede neural é responsável pelo controle e a outra pelo modelamento da planta (Beale, Hagan, & Demuth, 2010).

7.1 Identificação do Processo

O modelo NARX (*Nonlinear Autoregressive Network with Exogenous Input*), figura 7.2, é usado para identificação do processo. O modelo é uma rede neural dinâmica recorrente, com conexões de realimentação que envolve várias camadas da rede. O modelo NARX é baseado no modelo linear ARX, o qual é geralmente usado no modelamento de series temporais.




Figura 7.2 - Rede neural NARX

A camada oculta, camada 1, da rede NARX é composta por 30 (trinta) neurônios interconectados, e pela de ativação função tangente sigmoide. Na figura 7.3 poder ser observado a função tangencial.




Figura 7.3 - Função tangente sigmoide

A camada de saída, camada 2, da rede NARX é composta por 1 (um) neurônio e por uma função linear. Na figura 7.4 pode ser observada a função de linear.




Figura 7.4 - Função linear

Foram coletados os dados da vazão de água de entrada da torre de HCN, que é controlado pelo FRC-12002, além dos valores do pH da água de saída da torre de HCN através do AI-12001, conforme mostrado na figura 7.5.

No entanto, não foi possível coletar os dados da soda, pois o controlador PID, não foi capaz de manter o processo estável quando em automático, logo o

controlador permanece em manual. Além disso, o sistema atual não possui medidor de vazão de soda.

Para que fosse possível identificar o processo, foi simulada a saída do controlador AIC-12001, levando em consideração o pior caso possível, ou seja, grande amplitude de oscilação da saída do controlador. Na figura 7.6 é mostrado a simulação do sinal de saída do AIC-12001.




Figura 7.5 - Dados para identificação do processo

O desempenho da rede NARX foi analisado com base nos gráficos de correlação, conforme mostrado na figura 7.7.




Figura 7.6 - Sinal de saída AIC-12001

O valor de R indica a correlação entre a saída e o alvo. Quando $R=1$ indica que a correlação linear entre a saída e o alvo é exata. No entanto valores de R próximos de zero, indicam que não há correlação linear entre a saída e o alvo.

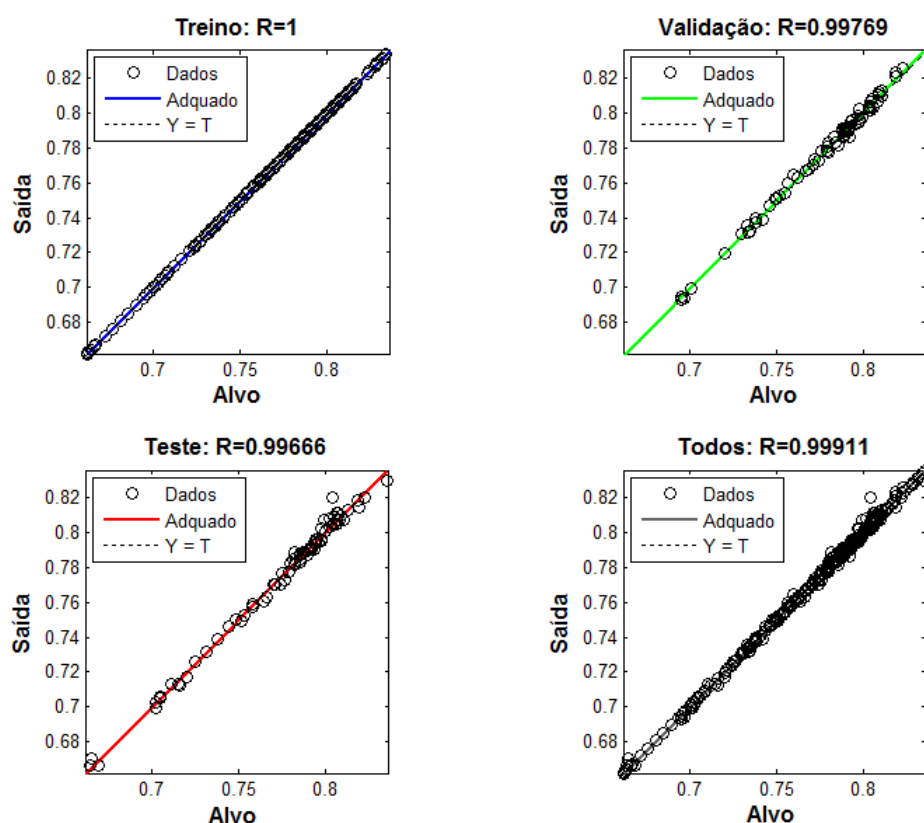


Figura 7.7 - Gráficos de correlação rede neural NARX

A linha pontilhada, do gráfico de correlação, representa o resultado perfeito, ou seja, saída é igual ao alvo. A linha sólida representa o melhor ajuste da regressão linear entre a saída e o alvo. Conforme observado na figura 7.7 os gráficos de correlação do modelo NARX apresentaram desempenho satisfatório.

Na figura 7.8, é apresentado o erro do modelo NARX entre a saída real e a saída estimada.




Figura 7.8 - Erro rede neural NARX

Com base nas informações apresentada na figura 7.7 - gráficos de correlação rede neural narx e figura 7.8 - erro rede neural narx, a rede neural NARX usada para modelamento da planta apresentou resultados satisfatório no modelamento do processo.

7.2 Controlador Neural Adaptativo de Modelo de Referência.

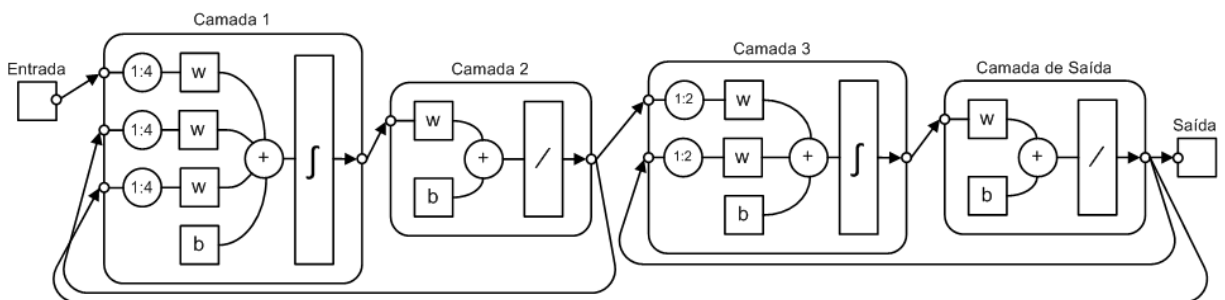


Figura 7.9 - Controlador MRAC

A figura 7.9 mostra o controlador neural MRAC, esta arquitetura de controle neural possui quatro camadas. Sendo as camada 1 e camada 2 compondo o controlador, e as camada 3 e camada 4 (camada de saída) compondo o modelamento da planta.

As camadas que formam o controlador são compostas pela seguinte configuração: camada 1 contém 30 neurônios e função tangente sigmoidal. A função tangencia é mostrada na figura 7.3. A camada 2 contém 10 neurônios e função de transferência linear, figura 7.4.

As camadas do controlador neural que modelam a planta estão configuradas da seguinte forma: camada 3 composta por 30 neurônios e pela função de transferência tangente sigmoidal, figura 7.3, a camada 4 (camada de saída) é composta por 1 neurônio e pela função de transferência linear, figura 7.4.

Um intervalo de 500 amostras do processo foi selecionado para treinamento do controlador neural MRAC. Os dados usados foram: água de entrada controlada pelo controlador FRC-12002, saída do controlador PID AIC-12001 que representa a soda que esta sendo aplicada no interior da torre, e valor do pH medido a partir do pH-metro AI-12001, esses dados são mostrado na figura 7.10. Nenhuma técnica para seleção das amostras para treinamento do controlador neural foi aplicada no desenvolvimento deste trabalho, os dados foram selecionados com base no conhecimento sobre o comportamento do processo. Os controles foram ajustados a fim de manter o processo em regime estável, sendo essa a melhor condição para a coleta de dados para o desenvolvimento do trabalho.




Figura 7.10 - Dados de processo para treinamento do controlador neural MRAC

A vazão de vapor S3 é alimentada via FFRC-12001 proporcionalmente a quantidade de água a ser tratada na unidade que é controlada pelo FRC-12002, conforme mostrado na figura 7.11.

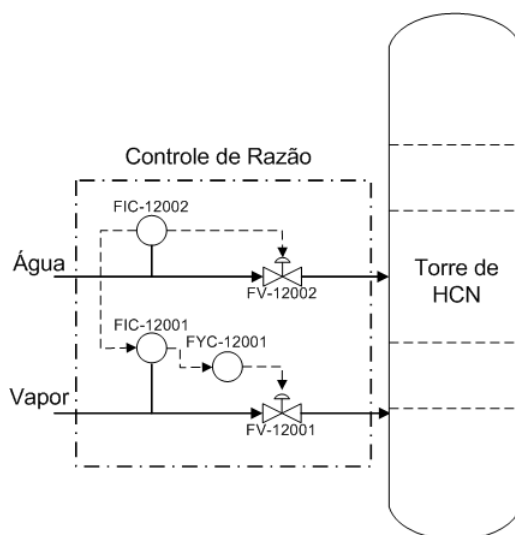


Figura 7.11 - Controle de razão torre de HCN

Como a malha de controle de razão tem apresentados resultados satisfatórios, conforme mostrado na figura 7.12, não houve a necessidade de usar os dados do FFRC-12001 no desenvolvimento do controlador neural.




Figura 7.12 - Dados do controle de Razão

O controlador neural MARC foi treinado utilizando o Matlab R2010b, que fornece um modelo de controle MARC com base em redes neurais. Este modelo foi

alterado, para que fosse possível carregar os dados coletados da torre de HCN para simulação do controle.

Após ajustar as matrizes de entrada e saídas de dados do controlador neural proposto, foi analisado o modelo de controle neural com base nos gráficos de correlação. O gráfico de correlação que apresenta a relação entre a saída da rede neural e o alvo é mostrado na figura 7.13.




Figura 7.13 - Correlação entre a saída da rede e o Alvo

O valor de correlação entre 0,9 e 1,0 é considerado suficiente para aplicações práticas, principalmente em sistemas de controle. Os resultados para o modelo proposto mostram correlação acima 0,9. Indicando que o aprendizado foi satisfatório, ou seja, a saída da rede neural e o alvo estão próximos.

A comparação entre a saída real e a saída estimada pelo modelo neural são apresentadas na figura 7.14, ambas apresentam o mesmo comportamento, no entanto existe uma pequena diferença.




Figura 7.14 - Saída real e saída estimada

Na figura 7.15 mostrado o erro entre a saída real e a saída do controlador neural.




Figura 7.15 - Diferença entre saída real e saída do controlador neural

7.3 Teste do Modelo de Controle Neural

O sinal de saída do controlador AIC-12001 é enviado para as bombas dosadoras de soda, 12-1117-01 e 12-1117-06. O controlador deve ser capaz de fazer as correções necessárias para controlar o pH da água, sem apresentar grande variabilidade, ou seja sem o consumo excessivo de soda.

A fim de avaliar o comportamento do controlador neural proposto, após a identificação e o treinamento das redes que compõem a arquitetura de controle. Aplicou-se na entrada do controlador os dados da vazão de água de processo FRC-12002 e os dados do pH, que é monitorado pelo AI-12001.

Na figura 7.16, pode ser observado a resposta do controlador neural. A saída do controlador apresenta oscilação, mas faz as devidas correções a fim de controlar o pH da água. Netas condição o controlador esta mantendo o pH dentro dos limites aceitáveis, mas com consumo excessivo de soda.




Figura 7.16 - Resposta-1 do controlador neural

Os resultados do controlador neural após novo treinamento podem ser observados nas figura 7.17 e figura 7.18.




Figura 7.17 - Resposta-2 do controlador neural

Mesmo após os treinamentos e conseqüentemente ajustes nos pesos das conexões dos neurônios, a saída do controlador apresenta grandes oscilações nos instantes iniciais. No entanto as oscilações diminuem e controlador neural estabiliza e apresenta as correções necessárias. Neste caso o controlador mantém o pH da água dentro dos limites aceitáveis sem apresentar alto índice de variabilidade, ou seja, sem consumo excessivo de soda.




Figura 7.18 - Resposta-3 do controlador neural

A figura 7.19, mostra a saída controlador neural após várias simulações, nesta situação a saída do controlador ainda apresenta elevado valor de máximo de sobre sinal, mas logo após a saída do controlador faz as correções necessárias sem apresentar grandes variações.




Figura 7.19 - Resposta-4 do controlador neural

Os resultados apresentados mostram que a arquitetura de controle neural usando o controle adaptativo de modelo de referência, tem condições de manter o valor do pH dentro dos valores aceitáveis sem apresentar grandes variações na saída e sem o consumo excessivo de soda.

8 CONCLUSÕES

O controle de pH é comum nos processos químicos, petroquímicos e indústrias de biotecnologia. Este controle é encontrado nas unidades de tratamento de efluentes, água de alimentação de caldeira entre outras, e deve ser mantido dentro de limites rigorosos, a fim de atender legislações ambientais e preservar a integridade dos equipamentos. No entanto o pH é conhecido pelo seu comportamento não linear devido a relação logarítmica entre a concentração de íons de hidrogênio $[H^+]$ e o nível do pH, tornando seu controle uma tarefa complicada. Devido a esta característica, a implementação de técnicas de controle avançado baseado em teoria de sistemas lineares não apresentam resultado satisfatório no processo de neutralização do pH.

A solução proposta para este problema é a implementação de técnicas de controle como método de modelagem online com base em rede neurais. Estas técnicas são baseadas na aplicação de estruturas não lineares variantes no tempo, tais como modelo ARX, ou ainda modelo NARX que são aplicadas no controle de pH. Redes neurais artificiais são aplicadas em arquiteturas de controle, permitindo o modelamento e o controle de processos dinâmicos não lineares como pH.

Este trabalho teve como objetivo propor uma arquitetura de controle com base em redes neurais, a fim de controlar o pH da água que sai da torre HCN. A arquitetura de controle proposta foi o controle adaptativo de modelo de referência, que é composta por duas redes neurais, sendo uma rede neural responsável pela identificação e a outra pelo controle do processo. A definição deste controle foi realizada com base na pesquisa de artigos científicos, pois os resultados apresentados mostraram-se satisfatórios no controle de processos com características não lineares e variantes no tempo.

O desempenho das redes neurais que compõem a arquitetura de controle proposta foi analisado com base nos gráficos de correlação. Esses resultados mostraram que o controlador neural pode ser aplicado no controle do processo de neutralização da água da torre de HCN. As simulações realizadas visando avaliar o

desempenho do sistema de controle mostraram-se satisfatórios, pois o controlador manteve o pH dentro dos limites estabelecidos. No entanto para melhorar o desempenho do sistema de controle, é necessário obter e usar no treinamento das redes neurais os valores reais de soda que é usado no processo de neutralização, pois a saída do controlador apresenta elevada amplitude de oscilação nos instantes iniciais, que podem vir a causar oscilações bruscas no processo.

Uma das melhorias na arquitetura de controle proposta que podem melhorar significativamente os resultados apresentado, seria primeiramente a instalação de um instrumento para medir a vazão de soda que é injetada na torre de HCN (variável manipulada). Outra possibilidade é a implementação de um método de previsão, a fim de prever o consumo de soda que será usada no processo de neutralização. Ou ainda, a instalação de um pH-metro para medir o pH da água de entrada, pois com essa informação seria possível para o controlador antecipar as correções. Com isso, é possível melhorar a qualidade e a quantidade das informações das variáveis de processo, que contribuirão significativamente na análise do comportamento do processo, e na implementação de um controlador neural mais preciso.

9 REFERENCIAS

Beale, M. H., Hagan, M. T., & Demuth, H. B. (2010). *Neural Network Toolbox 7 - User Guide*. Matworks.

Bonilla, M., Baruch, I., Flores, J. M., Goire, M. M., & Nenkova, B. (2003). Model Reference Adaptive Neural Controller of a Variable Structure System. *Bulgarian Academy of Sciences* , pp. 3-13.

Braga, A. P., Ludimir, B. T., & Carvalho, A. C. (2000). *Redes Neurais Artificiais - Teoria e Aplicações*. Rio de Janeiro: LTC.

Burns, R. S. (2001). *Advanced Control Engineering*. Plymouth: Butterworth Heinemann.

Douratsos, I., & Gomm, J. B. (2007). Neural Network Based Model Reference Adaptive Control for Process with time Delay. *International Journal of Information and Systems Sciences* , 161-179.

Darogheh, N.; High gain adaptive control of a neutralization process pH. Control and Decision Conference. Dept. of Instrum. & Maintenance, Iranian Nat. Petrochem. Co., Iran, p. 3477 – 3480, June 2009.

Draeger, A., Engell, S., & Ranke, H. (October de 1995). Model Predictive Control Using Neural Networks. *IEEE* , pp. 61-66.

Elarafi, M. G., & Hisham, S. B. (October de 2008). Modeling and Control of pH Neutralization Using Neural Network Predictive Controller. *International Conference on Control, Automation and Systems* , pp. 1196-1199.

Henson, M.A.; Seborg, D.E.; Adaptive nonlinear control of a pH neutralization process. : Control Systems Technology, IEEE Transactions. Dept. of Chem. Eng., Louisiana State Univ., Baton Rouge, LA. p. 169 – 182, sept 1994.

Hong, T.; Morris, A.J.; Karim, M.N.; Zhang, J.; LUO, W.; Nonlinear control of a wastewater pH neutralisation process using adaptive NARX models. Systems, Man, and Cybernetics, 1996., IEEE International Conference. Dept. of Chem. & Process Eng., Newcastle upon Tyne Univ., p. 911 – 916, oct 1996.

Ge, S. S., Hang, C. C., & Zhang, T. (6 de December de 1999). Adaptive Neural Network Control of Nonlinear Systems by State and Output Feedback. *IEEE* , pp. 818-828.

Gomm, J. B., Doherty, S. K., & Williams, D. (3 de September de 1996). Control of pH In-Line Using A Neural Predictive Strategy. *IEEE* , pp. 1058-1063.

Hadjiski, M.; Boshnakov, K.; Galibova, M. Neural networks based control of pH neutralization plant. Intelligent Systems .Univ. of Chem. Technol. & Metall., Sofia, p. 7 - 12, 2002.

Hall, R. C., & Seborg, D. E. (23 de June de 1989). Modelling and Self-Tuning Control of a Multivariable pH Neutralization Process. *IEEE* , pp. 1822-1827.

Henson, M. A., & Seborg, D. E. (Augst de 1994). Adaptive Nonlinear Control of a pH Neutralization Process. *IEEE* , pp. 169-182.

Hong, T., Morris, A. J., Karim, M. N., Zhang, J., & Luo, W. (14 de October de 1996). Nonlinear Control of a Wastewater pH Neutralisation Process Using Adaptive NARX Models. *IEEE* , pp. 911-916.

Kang, T.-S., Yoon, T.-W., Yang, D. R., & Yoon, S.-S. (December de 2000). Adaptive Output Feedback Nonlinear Control of a pH Process with an Input Constraint. *IEEE* , pp. 4538-4543.

Liu, B., Li, H., & Wu, T. (19-21 de May de 2009). Neural Network Identification Method Applied to the Nolinear System. *IEEE* , pp. 120-124.

Kumpati, N. S., & Kannan, P. (March de 1990). Identification and Control of Dynamical Systems Using Neural Networks. *IEEE* , pp. 4-27.

Luo, W.; Morris, A.J.; Karim, M.N.; Martin, E.B.; Hong, T.; Online identification of a pH waste water neutralisation process using time-varying nonlinear ARX models. Systems, Man, and Cybernetics, 1996., IEEE International Conference. Dept. of Chem. & Process Eng., Newcastle upon Tyne Univ., p. 107 – 112, Oct 1996.

Jacobs, O.L.R.; Hewkin, P.F.; While, C.; Online computer control of pH in an industrial process. Control Theory and Applications, IEE Proceedings. University of Oxford, Department of Engineering Science, Oxford, UK , p. 161 – 168, july 1980.

Nikraves, M., & Stanford, T. G. (12-14 de March de 1995). Optimal Controller for Nonlinear Systems Via Dynamic Neural Network Control (DNNC). *IEEE* , pp. 514-518.

Patiño, H. D., & Liu, D. (February de 2000). Neural Network-Based Model Reference Adaptive Control System. *IEEE* , pp. 198-204.

Petrovic, I., Baotic, M., & Peric, N. (6 de August de 2002). Model structure selection for nonlinear system identification using feedforward neural networks. *IEEE* , pp. 53-57.

Shinskey, F. G. (1967). *Process Control System Application Design Adjustment*. Ney York: McGraw-Hill.

Shinskey, F. G. (1996). *Process Control Systems*. New York: McGraw Hill.

Zuben, F. J., & Attux, R. R. (s.d.). Fundamentos Básicos de Álgebra Linear e Otimização. Unicamp.

Sing, C.H.; Postlethwaite, B.; pH control: handling nonlinearity and deadtime with fuzzy relational model-based control. Control Theory and Applications, Dept. of Chem. & Process. Eng., Strathclyde Univ., Glasgow, v.144, p. 263 – 268, may. 1997.

Zeybek, Z. Albaz, M.; Fuzzy-dynamic matrix pH control for treatment of dye wastewater plant. Computational Intelligence and Multimedia Applications .Dept. of Chem. Eng., Ankara Univ., Turkey, p. 118 – 123, aug. 2005.